Production Systems and Information Engineering
Volume 11 (2), pp. 49-60
doi: https://doi.org/10.32968/psaie.2023.2.5

TELJESÍTMÉNY NÖVELÉS SIMD UTASÍTÁSKÉSZLET SEGÍTSÉGÉVEL

PÉTER MILEFF
University of Miskolc, Hungary
Institute of Information Technology
mileff@iit.uni-miskolc.hu

Abstract. A számítógépes alkalmazás fejlesztés hosszú múltra tekint vissza. A hardver folyamatos fejlődésével mind a szoftverek, mind pedig a alkalmazások készítését lehetővé tevő programozási nyelvek és keretrendszerek is együtt változtak. Ahogy haladunk az időben előre, úgy váltak elérhetővé az egyre nagyobb kapacitású számítógépek. Ez hatással volt a fejlesztési folyamatra is, hiszen megjelentek a magasabb szintű programozási nyelvek, egyre magasabb szintű API-k váltak elérhetővé, lassan eltűntek a pointerek, memória foglalások és felszabadítások is a programozás területéről. A magas szintű nyelvekre való váltással azonban egyre inkább eltűnt a programok optimalizálása vagy annak lehetősége, mivel bizonyos hatékonyságot növelő lehetőségek a magasabb szintű nyelvekben nem vagy csak korlátozottan elérhetőek. Jelen cikk ezért a hétköznapi programozás köreiben "elfeledett", a modern CPU-k által támogatott SSE/AVX SIMD párhuzamosítási lehetőségek adta előnyökkel foglalkozik mélyebben. Bemutatásra kerül, hogy a CPU-ban olyan tartalékok vannak, amelyekkel bizonyos teljesítménykorlátok messze kitolhatók.

Keywords: SIMD, teljesítmény optimalizáció, SSE, AVX

1. Bevezetés

Egy adott hardver architektúra teljesítményének maximalizálása a futó szoftverek precíz optimalizálásával mindig központi területet foglalt el az informatika tudomány történelmében. Természetesen kezdetben, az első személyi számítógépek megjelenésekor ezek a kérdések sokkal égetőbbek voltak, mint manapság, hiszen azok a számítógépek meglehetősen gyenge számítási kapacitással rendelkeztek. A számítógépes játékipar azonban már a kezdetektől lehetőségnek tekintette ezeket és elindult a ma már giga méreteket öltő játékvilág. Mivel a hardverek nem voltak erősek, GPU sem létezett még, nagyon nagy odafigyelést igényelt egy játék vagy olyan egyéb szoftver elkészítése, amely már nagyobb számításokat szeretett volna végezni. Már rendelkezésre állt a C nyelv, amely akkor még magas szintűnek számított. A programok nagy része ebben készült a sebesség kritikusság miatt. Azonban az önmagában ez nem volt elég. A limitált hardver miatt a programozók gépközeli nyelveket használtak a kritikus részek elkészítésére. A számítógépes játékok tipikus mintapéldája volt ennek a vonalnak. A képi megjelenítés motorja, a vektoriális és egyéb kritikus számítások általában Assembly-ben készültek, majd később SIMD utasításkészlettel. Több nyelv erre nagyon jó lehetőséget adott. Képesek voltunk akár néhány sor Assembly kódot egy *for ciklus* belsejébe szúrni a megfelelő sebességért cserébe. Meglehetősen nagyszerű eredmények születtek a precíz és mélyreható optimalizálás, valamint a hardver megfelelő szintű

kihasználtsága miatt.

A technológia fejlődésével a hardver egyre erősebb lett. Megjelentek és terjedni kezdtek a magasabb szintű nyelvek: Java, C#, Javascript, Scala, SWIFT, stb. Ma már teljesen természetes, ha ezekkel a technológiákkal készítünk alkalmazásokat. A hardver fejlődését tehát követte a szoftver fejlődése is. A magasabb szintű nyelvek növelték az ipari produktivitást. Egységnyi idő alatt gyorsabban készülhettek el a programok, hiszen a programozó már nem feltétlenül a pointerekre fókuszált, vagy a memória felszabadítására, hanem kizárólag az üzleti logikára. Az ipar természetesen nagyon elégedett ezekkel a technológiákkal, hiszen a szoftver gyakran így gyorsabban készül el. Ennek a fejlődési vonalnak a nagy hátránya azonban az, hogy a szoftverek sokszor nem megfelelően optimalizáltak. Sokkal erősebb hardver (gyorsabb CPU, több memória) szükséges hozzá, mint amit valójában igényelne. Mindez azért, mert a magasabb szintű nyelvekkel készített szoftverek egyre több függőséggel rendelkeznek, egyre több a réteg egymáson, valamint sokszor hiányzik az alacsonyabb programozhatóság lehetősége. A hardver erőssége miatt legtöbbször a programozóknak ma már nincs meg az optimalizálási "kényszere", valamint mivel a magas nyelvekben már nem nyúlhatunk le olyan szintre, amivel megfelelő optimalizációt elvégezhetnénk.

Az úgynevezett SIMD utasításkészletek már a korai CPU-ban elérhető voltak (MMX, SSE), az utóbbi években pedig tovább fejlődött (NEON, AVX, AVX512) a technológia. Kezdetben a játékfejlesztők szent Grálja volt, hiszen az akkori gépek teljesítménye (és a GPU hiánya) önmagában nem volt elégséges egy komolyabb háromdimenziós játék futtatására [14]. Azonban egy sikeres MMX/SSE optimalizációval nagymértékű teljesítmény növekedést lehetett elérni. Ez tette lehetővé az olyan játékok, mint a Doom, Quake, Unreal család az akkori hardvereken való futás lehetőségét. A mai játékok inkább GPU intenzív programoknak tekinthetők, a CPU oldalon nem igazán használnak kézi SIMD alapú optimalizációt. A programozás világában jellemzően magasabb szintű nyelveket (pl. C#) használnak, mert ezekkel a fejlesztés produktivitása jelentősen nőhet. Egyéb esetleg kritikus számítást igénylő programok esetében pedig a több szál alkalmazása az elsődleges megoldási alternatíva.

A SIMD megoldások direkt használata az átlagos programozó mindennapi munkájából kiszorult. Ennek oka, hogy a SIMD alkalmazása magasabb szintű tudást igényel. A mai fordítók egyre fejlettebbek, képesek a kódot úgy fordítani, hogy azok használják a SIMD bővített utasításkészletet. Bár ez nagyszerű dolog, a legtöbb esetben nem veszi el a versenyt a direkt SIMD kódokkal.

Jelen cikkben a SIMD alapú párhuzamosítási megoldásokat vizsgáljuk, legfőképpen az SSE és AVX kiterjesztéseket. Egy saját készítésű benchmark csomagon keresztül mutatjuk be a SIMD által nyújtott potenciális sebesség növekedést.

2. Irodalmi áttekintés

A processzor SIMD típusú utasításkészlet kiterjesztése hosszú múltra tekint vissza. A fejlődés ma is folyamatos, bár nem olyan látványos és médiaközpontú, mint a GPU-k esetben. Az alábbiakban a legfontosabb mérföldköveket ismertetjük.

MMX™ technológia - Intel® Pentium Pentium® with MMX™ és Pentium® II processzorok (1996): 64 bites MMX (Multimedia Extensions) regiszterek bevezetése az egész típusú SIMD műveletekhez [13]. Támogatja a SIMD műveleteket rendezett *byte*, *word* és *double-word* egész számokon. Hasznos multimédiás és kommunikációs szoftverekhez.

3DNOW - AMD (1998): olyan SIMD utasításokkal egészíti ki az alap x86 utasításkészletet, lehetővé téve a lebegőpontos vektorműveletek vektoros feldolgozását *vector regiszterek* segítségével, ami nagymértékben képes javítani a grafika intenzív alkalmazások teljesítményét. A 3DNow-t megvalósító első mikroprocesszor az AMD K6-2 volt, amelyet 1998-ban mutattak be. Amennyiben az alkalmazás megfelelően integrálta a technológiát, körülbelül 2-4-szeresére növelte a sebességet [12].

SSE – Intel® Pentium Pentium® III processor (1999): Eredeti neve "Katmai New Instructions" (KNI), mert a Katmai volt az első Pentium III kódjelzése. 128 bites kiterjesztett memóriakezelő (XMM) regisztereket vezetett be a SIMD egész számokhoz és FP-SP operandusokhoz. Nagy előnye, hogy egyszerre hajtja végre az FP-t és a SIMD-t. Továbbá bevezetésre kerültek olyan utasítások, amelyek lehetővé tették az adatok előzetes betöltését (*data prefetch*). Az SSE utasításkészlet hasznos 3D geometriához, 3D rendereléshez és videó kódolásához/dekódolásához.

SSE2 – Intel® Pentium Pentium® 4 and Intel 4 and Intel® Xeon processors ™ (2000): Extra 64 bites SIMD egész szám támogatás. Ugyanazok az XMM regiszterek a SIMD egész számokhoz és a lebegőpontos kettős pontossághoz (FP-DP). 144 új adattámogatási utasítással rendelkezik (nincs új regiszter). Támogatja a gyorsítótárazhatóságot és a memóriarendezési műveleteket. Az utasításkészlet a 3D-s játékokra, a számítógéppel segített tervezési alkalmazásokra és a videó kódolására/dekódolására összpontosított. Bár az SSE2 akár négy adaton egyszerre tudott műveletet végezni, a teljesítmény nagyjából megegyezett az MMX-szel, amely mindössze két elemben működött. A teljesítmény vesztés ilyenkor általában azért következik be, mert az adatok nem megfelelően rendezettek (16 byte-ra) a memóriában.

SSE3 – Intel® Pentium® 4 Processor (2004): A nem megfelelően igazított adatok miatti teljesítmény problémák megoldása érdekében az SSE3 új utasításokat tartalmaz az ilyen típusú adatok betöltésre, minimalizálva az időzítési "büntetéseket" (*time penalties*). Felgyorsítja a Streaming SIMD Extensions technológia, a Streaming SIMD Extensions 2 technológia és az X87 technológia, valamint az X87-FP matematikai képességek teljesítményét. Hasznos egyes 3D-műveletek (Quaternions) összetett aritmetikai és videokodek algoritmusaiban.

SSSE3 – Intel ® Core® 2 Processor (2006): Az alkalmazás teljesítményének javítása (új utasítások, mint például a szorzás és összeadás és a vektor igazítás). Lehetőséget ad specifikus alkalmazások igényeihez való igazításra.

SSE4 (2007): Az SSE4 54 új utasítást tartalmaz (47 az SSE4.1-ben és 7 az SSE4.2-ben), amelyek a karakterlánc-feldolgozásra szolgálnak. Az új utasítások segítségével a CRC-32 hibaérzékelő folyamat tovább gyorsítható volt. Az SSE4 végleges verziója az SSE4.2.

Az AVX kiegészítés

Az Intel úgy döntött, hogy a számításokat még szélesebb regiszterekbe helyezi át, és bevezette az *Advanced Vector Extensions* (AVX, más néven *Sandy Bridge New Extensions*) nevű új megoldást. Az AVX az Intel és az AMD mikroprocesszoraihoz készült x86 utasításkészlet architektúra kiterjesztése, amelyet az Intel 2008 márciusában indítványozott. Az első olyan processzor, amely támogatta az AVX-et, az Intel által kiadott Sandy Bridge család volt 2011 első negyedévében, majd később pedig az AMD a Bulldozer processzorai 2011 harmadik negyedévében [7]. Az AVX új funkciókat, új utasításokat és új kódolási sémát kínál. A technológia a következőket tartalmazza:

- 16 darab 256-bites regiszter, YMM0-YMM15

- Három operandus kód írásának képessége assembler alapokon
- A VEX kódolási sémát javasolja, amely megnöveli a műveleti kódok terét
- A VEX előtag hozzáadásával támogatja a régi SSEx utasításokat is

Az AVX második, 2012-ben kiadott verziója számos egész művelet 256 bites regiszterekre való kiterjesztését tartalmazza. Az AVX2 támogatja a "*gather/scatter*" műveleteket a regiszterek betöltésére/tárolására a nem szomszédos memóriahelyekről/helyekre. Nagy zűrzavart okozott az, hogy az Intel és az AMD is megváltoztatta az SSE5-tel kapcsolatos terveit, az utasításkészletek jövőbeli irányait. Ugyanis a Bulldozer, az AMD legújabb mikroarchitektúrája XOP és FMA4 utasításkészleteit valósítja meg, és kompatibilis az AVX-szel is. A Piledriver és a Haswell pedig az AMD és az Intel következő mikroarchitektúrái voltak, amelyek célja további szorzási és összeadási utasítások támogatása mind a lebegőpontos, mind az egész műveletekhez.
2011-ben az ARM is SIMD kiterjesztéseket vezetett be az ARM-Cortex architektúráiba a NEON technológiájukkal. A NEON SIMD egység 128 bit széles és 16 darab 128 bites regisztert tartalmaz, amelyek 32 és 64 bites regiszterként használhatók. Ezeket a regisztereket azonos adattípusú elemek vektorainak tekinthetjük, melyek az előjeles/előjel nélküli 8, 16, 32, 64 bites és egyetlen precíziós lebegőpontos adattípusok lehetnek.

3. SIMD áttekintése

Az *Single Instruction, Multiple Data* (SIMD) a párhuzamos számítógépek egyik osztálya a Flynn-féle taxonómiában [3]. Több feldolgozó elemmel rendelkező számítógépeket ír le, amelyek ugyanazt a műveletet hajtják végre több adaton egyszerre. Ezzel szemben a hagyományos szekvenciális megközelítést, amely minden egyes adat feldolgozásához egy utasítást használ, skaláris műveleteknek nevezzük. Röviden, a SIMD lehetővé teszi több adatérték egyetlen utasítással való feldolgozását. Az ilyen gépek tehát kihasználják az adatszintű párhuzamosságot, de nem a párhuzamosítást: vannak egyidejű (párhuzamos) számítások, de egy adott pillanatban csak egyetlen folyamat (utasítás) hajtódik végre. A SIMD különösen előnyös olyan feladatoknál, ahol egy nagyobb adathalmazon kell valamilyen számítást végrehajtani. Tipikusan ilyen feladatok találhatók meg a játékokban (vektorok, mátrixok számításai) vagy a multimédiás szoftverekben (képszintézis, kép transzformáció).
Általában egy SIMD egység bemenetként két vektort kap. Feladata az, hogy ugyanazt a műveletet mindkét vektor adatain végrehajtsa, majd végeredményként egy vektort ad ki [1]. Az 1. ábra egy egyszerű példát mutat be, amelyben egy SIMD egység négy műveletet hajt végre párhuzamosan:

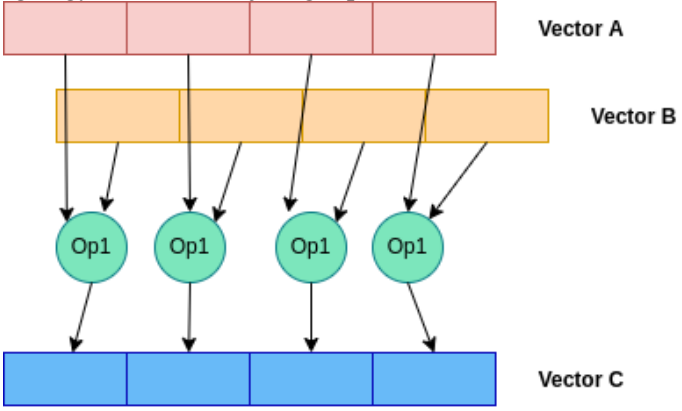

1. ábra SIMD művelet végrehajtás

3.1. SSE regiszterek

Az SSE-hez 8 darab (64 bites módban 16) XMM regiszter (XMM0-7(15)) tartozik, melyek 128 bites regiszterek. Egy tipikus 128 bites SIMD regiszter a következőket tartalmazhatja:

- 16 darab 8 bites egész érték (int8x16 and uint8x16)
- 8 darab 16 bites egész érték (int16x8 and uint16x8)
- 4 darab 32 bites egész érték (int32x4 and uint32x4)
- 4 darab egyszeres pontosságú lebegőpontos érték (float32x4)
- 2 darab dupla pontosságú lebegőpontos érték (float64x2)

2.*ábra* SSE (128 bites) regiszterek [4]

3.2. Az AVX kiterjesztés

Az AVX tizenhat YMM regisztert használ a SIMD operációk elvégzésére. Minden YMM regiszter képes egyidejű műveleteket (matematikai) tárolni és végrehajtani: nyolc 32 bites egyszeres pontosságú lebegőpontos számon vagy négy 64 bites duplapontos lebegőpontos számon. A SIMD regiszterek szélessége 128 bitről 256 bitre nőtt, és átnevezték XMM0–XMM7-ről YMM0–YMM7-re (x86–64 módban, XMM0–XMM15-ről YMM0–YMM15-re) [7].

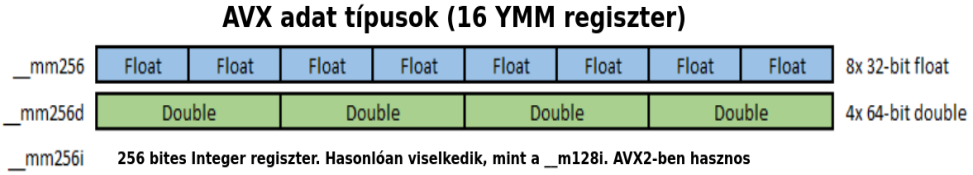

3. ábra AVX (256 bites) regiszterek [4]

A régebbi SSE utasítások továbbra is használhatók. Ezt a VEX előtag teszi lehetővé, amely az YMM regiszterek alsó 128 bitét használja a művelet elvégzésére. Az AVX bevezette a VEX kódolási sémának nevezett háromoperandusú SIMD utasítás formátumot, ahol a cél regiszter különbözik a két forrás operandustól. Például a hagyományos a = a + b kétoperandusú formát használó SSE utasítás most már használhat egy háromoperandusú c = a + b formát, megőrizve mindkét forrás operandust. Eredetileg az AVX háromoperandusos formátuma a SIMD operandusokkal (YMM) rendelkező utasításokra korlátozódott, és nem tartalmazott általános célú regiszterekkel (pl. EAX) rendelkező utasításokat. Az említett VEX kódolást az AVX-512-vel bevezetett k0-k7 maszkregiszterekre vonatkozó utasításokhoz is használják.

A VEX kódolási séma új kódelőtag-készletet vezet be, amely kiterjeszti az opkód teret és lehetővé teszi, hogy az utasítások kettőnél több operandust tartalmazzanak, és lehetővé teszi, hogy a SIMD vektor regiszterek 128 bitnél hosszabbak legyenek. A VEX előtag a régi SSE utasításokon is használható, így három operandusból álló formát adva nekik, és hatékonyabbá téve az interakciót az AVX utasításokkal anélkül, hogy VZEROUPPER és VZEROALL utasításokra lenne szükség. Az AVX utasítások a 128 bites és a 256 bites SIMD-t is támogatják. A 128 bites verziók hasznosak lehetnek a régi kód fejlesztésére anélkül, hogy ki kellene bővíteni a vektorizálást, és elkerülhető az SSE-ről AVX-re való átállás "büntetése". Emellett gyorsabbak is az AVX egyes korai AMD-megvalósításoknál. Ezt a módot néha AVX-128-nak is nevezik.

4. SIMD használata a gyakorlatban

Az SSE/AVX-képes CPU-k tartalmaznak olyan assembler utasításokat, amelyek lehetővé teszik az XMM és YMM regiszterekkel való dolgozást. Amennyiben szeretnénk kihasználni ezen lehetőségeket, akkor alkalmazásfejlesztés szempontjából természetesen az elsődleges kapcsolódási pontok a SIMD képességek kihasználására az alacsony szintű nyelvek és a fordítóprogramok, hiszen általuk készülnek el a megfelelő binárisok. A legtöbb fordító (pl. GCC, Clang, Intel, Microsoft Visual C++, stb) rendelkezik bizonyos szintű automatikus vektorizálással / SIMD támogatással, amelyek az utóbbi években sokat fejlődtek. A fejlesztő eszközök pedig általában lehetőséget adnak arra, hogy a generált bináris futtatása során beletekinthessünk az adott programrész assembler kódjába, így ellenőrizve a generált kód minőségét.

Természetesen arra is van lehetőség, amennyiben valaki egyedi SIMD kódrészekkel szeretné gyorsítani programjának bizonyos részeit. Az egyik út ilyenkor a közvetlen assembly utasítások alkalmazása, amely ma már túl alacsony szintnek számít a programozók nagy részének. Példaként említhetjük, hogy míg korábban a játék motorok sebességkritikus részei/függvényei assembly-ben készültek, ma már nem mennek ilyen szintre le. Ennek természetesen egyik oka, hogy a GPU vette át az egyik legkritikusabb feladatot, a renderelést. A másik út egy könnyebb hozzáférést tesz lehetővé a SIMD utasításkészlet és funkciók használatához. A legtöbb fordítóprogram rendelkezik egy úgynevezett "*intrinsic*" függvénykönyvtárral, így a programozóknak nem kell közvetlenül assembler kódot írni, használni. Az *intrinsic* függvénykönyvtárak azért jöttek létre, hogy az assembler utasításokat függvényekkel fedje el és a SIMD funkciók használata ne különbözzön egy megfelelő paraméterekkel rendelkező függvények meghívásától.

Az *intrinsics* függvények használata nem különbözik bármely más C/C++ alapú függvénykönyvtár használatától. A programozó include-álja a használni kívánt intrinsic típusának megfelelő header fájlt (pl. *#include* <*xmmintrin.h*>), majd meghívja a kívánt függvényt.

Ahhoz, hogy az SSE/AVX utasításkészleteket használni tudjuk, rendelkeznünk kell a megfelelő architektúrával. Az SSE/AVX lefordított binárisok csak olyan gépeken képesek futni, amely rendelkezik a megfelelő instrukció családdal. A különböző CPU-k támogatása érdekében a platformspecifikus binárisokat külön, platformspecifikusan kell lefordítani.

Az SSE/AVX intrinsic függvényei a következő elnevezési konvenciót használják (Intel, 2011):

_<vector_size>_<intrin_op>_<suffix>

- <vector_size>: a regiszter méretét jelző rész. mm a 128 bites vectorok számára (SSE), *mm256* a 256 bites vectorok számára (AVX és AVX2), és mm512 az AVX512 számára.
- <intrin_op>: az alkalmazott intrinsic operáció neve. Pl. add, sub, mul, stb.
- <suffix>: az adattípusra utaló rész, melyek: *ps* a *float*, *pd* a *double*, és az *ep<int_type>* az integert jelöli. *epi32* az előjeles 32 bites integer, *epu16* az előjel nélküli 16 bites integer, stb.

1. táblázat SSE/AVX adattípusok

Utasításkészlet	Float	Double	Integer
SSE	*__m128*	*__m128d*	*__m128i*
AVX	*__m256*	*__m256d*	*__m256i*

Fontos megjegyzés, hogy az XMM és az YMM átfedik egymást. Az XMM regisztereket a rendszer a megfelelő YMM regiszter alsó feleként kezeli. Ez bizonyos teljesítményproblémákat okozhat az SSE és AVX kódok keverésekor. A programozás szintjén a *__m128i* és *__m256i* unióként kerültek megvalósításra, ezért az adattípusra megfelelően kell hivatkozni. A GCC fordító lehetővé teszi az adatokat tömbként történő elérését, így megkönnyítve a használatukat.

Az *intrinsic* függvények használata függ az alkalmazott fordító architektúrától. Ezért az elérhető függvényekről mindig a fordító dokumentációjából tájékozódhatunk.

4.1. A rendszer képességeinek felismerése

```
#!/bin/bash
#CPU flag detection
echo "****Getting CPU flag capabilities and number of cores"
cat /proc/cpuinfo  | egrep "(flags|model name|vendor)" | sort
| uniq -c
#Compiler capabilities. -march=native is required!
echo "****Getting GCC capabilities"
gcc -march=native -dM -E - < /dev/null | egrep "SSE|AVX" |
sort
```

A fenti sorokkal listázható a CPU-nk tulajdonságai/képességei (*flag*), amely általában egy hosszú lista. Amennyiben gépünk AVX kompatibilis, úgy a listában szerepelnie kell az AVX flag-nek. Ha az AVX2 is megtalálható, akkor a CPU támogatja ezen utasításkészletet is. Az AVX 8x32bit float vectors tárolására képes. Az AVX2 256 bites egész (integer) vektorokkal bővült (például 8x32bit integer). Ennek ellenére úgy tűnik, hogy a 256 bites egész vektorokat ugyanúgy hajtják végre, mint két 128 bites vektort, így a teljesítmény nem javul jelentősen az SSE 128 bites egész vektorokhoz képest. A szkript további részében a GCC képességek kerülnek lekérdezésre, amelyekből a **#define __AVX__ 1** pragmát kell keresni. Ez azt jelzi, hogy az AVX ágak engedélyezve lesznek.

Ha a GCC-t a megfelelő ***march*** flag nélkül futtatjuk, akkor nem kapjuk meg az **__AVX__** képességet, ezért a **-march=native** vagy **-mavx** jelzők használata szükséges. Az alapértelmezett GCC paraméterek általánosak, a megfelelő flag nélkül nem engedélyezi az AVX-et, még akkor sem, ha a CPU AVX-képes.

4.2. Fordító auto-vektorizáció

A mai GCC (pl. 13 verzió) fordító már nagyon fejlett. Az **-O3** vagy **-ftree-vectorize** optimalizálási kapcsolókkal a fordító ciklus-vektorizációkat keres (ne felejtsük el megadni a **-mavx** is). A fordítás eredménye során bár forráskód változatlan marad, de a fordító által összeállított kód teljesen más is lehet.

A GCC nem naplóz semmit az automatikus vektorizálásról, hacsak nincs engedélyezve néhány beállítás. Ha az autovektorizálás eredményeinek részleteire van szükségünk, használhatjuk az alábbi fordító kapcsolókat:

- **-fopt-info-vec** vagy **-fopt-info-vec-optimized:** A fordító loggolni fogja (sorszámmal együtt), hogy mely ciklusok kerültek vektorizálásra.
- **-fopt-info-vec-missed:** Részletes információ azokról a ciklusokról, amelyek nem kerültek vektorizálásra és számos további részletes információ
- **-fopt-info-vec-note:** Részletes információ minden ciklusról és optimalizálásról, amely megtörtént
- **-fopt-info-vec-all:** Minden korábbi opció együttesen

4.3. For ciklus automatikus vektorizálásának kritériuma

Nem minden ciklus vektorizálható. A vektorizálás sikeres végrehajtásához az alábbi követelményeknek kell megfelelnie egy ciklusnak:

- A ciklusszám nem változhat, ha a ciklus elindul. Ez azt jelenti, hogy a ciklus vége lehet egy dinamikus változó, amely tetszés szerint növeli vagy csökkenti az értékét, de ha a ciklus elindul, állandónak kell maradnia.
- A *break* és *continue* használatának korlátai vannak. Néha a fordító elég ügyes ahhoz, hogy elvégezze a vektorizációt, de lesznek olyan esetek, amikor a ciklus nem lesz vektorizálva.
- A cikluson belüli külső függvények meghívásának vannak bizonyos korlátai.
- Nem lehetnek adatfüggőségek a ciklu más indexeivel. Például ha a ciklus: for (int i=1; i<N; ++i) x[i]=x[i-1]*2; amelyet az *i* változóval járunk be, és az *x[i]* adat az előző *x[i-1]* értéktől függ. Mivel az AVX-regiszterek 8 darab *float*-ként vannak betöltve, a fordító nem tudja vektorműveletekre konvertálni a számításokat.
- A feltételes mondatok (if/else) akkor használhatók, ha nem változtatják meg a vezérlési folyamatot, és csak az *A* vagy *B* értékek feltételes betöltésére szolgálnak egy *C* változóba.

Az autovektorizálás előnye és célja, hogy a fejlesztőnek nem kelljen semmit változtatnia a kódon, és az autovektorizáció segítségével a magasabb szintű képességek kihasználhatók legyenek. Ez sok esetben működik is, azonban (különösen a nagy teljesítményű számítástechnikai alkalmazásokban) a ciklusokat és így a vektorizálást finomhangolni kell, vagy esetleg kézi SSE / AVX vektorizálással kell biztosítani a maximális átviteli sebességet.

4.4. Hiányzó funkciók az SSE/AVX intrinsics-ből

Integer osztás hiánya

Valamilyen oknál fogva az SSE és az AVX nem tartalmaz egész szám osztási operátort. Ennek leküzdésére az alábbi trükköket alkalmazzák:

- Az osztás megvalósítása hagyományos lineáris kódban. A vektorizált kód “megszakítása”, amelyben a normál változó(k)ba hozzuk vissza az adatot,

majd elvégezzük az osztást, végül az eredményt visszatöltjük újra vektor(ok)ba. A megoldás sajnos nem gyors.
- Az integer vektor float-ra konvertálása, az osztály elvégzése, majd ismét integer-re konvertálása
- A fordítási időben ismert osztók esetében van néhány olyan szám, amelyekkel az állandóval való osztást szorzássá alakíthatjuk.
- Kettővel való osztás biteltolási művelettel. A 2 egész számmal való osztás ugyanaz, mint a jobbra eltolás. Ez csak akkor lehetséges, ha az összes vektort két szám azonos hatványával osztjuk. Előjeles számok esetében mindig ügyeljünk az előjel bitre.

Trigonometriai függvények hiánya

A vektor *intrinsic* függvényei között nincsenek trigonometrikus függvények. A lehetséges megoldások ilyenkor ezek lineáris kóddal történő kiszámítása (vektorértékenként egyesével), vagy közelítő függvények létrehozása. A Taylor sorozat és a Remez közelítések jó eredményeket adnak, a gyakorlatban előszeretettel alkalmazzák őket.

4.4.1 Teljesítmény "büntetések"

Adat igazítás

A régebbi CPU-architektúrák nem képesek a vektorizációt használni, hacsak az adat mögötti memória nincs megfelelően a vektor méretéhez igazítva (SSE esetén 16 byte-ra). Bizonyos CPU-k képesek nem igazított adatokkal is dolgozni. Ez a működés azonban teljesítmény csökkenéssel, "büntetéssel" jár. A legújabb processzorokban a büntetés mértéke már elhanyagolhatónak tűnik, de a biztonság kedvéért jó ötlet lehet az adatokat továbbra is igazítani, ha nem jár túl sok munkával.

A GCC-ben az adatok igazítása ezekkel a változó attribútumokkal végezhető el: **__attribute__((aligned(16))) __attribute__((aligned(32)))**

SSE és AVX közötti átmenet

Egy további nagy probléma a régebbi SSE-könyvtárak és az új AVX-architektúra keverése. Mivel az XMM és az YMM az alsó 128 biten osztozik, az AVX és az SSE közötti átmenet meghatározatlan értékekhez vezethet a felső 128 biten. Ennek megoldásához a fordítónak el kell mentenie a felső 128 bitet, törölnie kell, végre kell hajtania az SSE műveletet, majd vissza kell állítania a régi értéket.

Ez észrevehető többletköltséget jelent az AVX műveleteknél, amely csökkenti a teljesítményt. Ez a probléma nem jelenti azt, hogy ne használhatnánk az *__m128*-at és az *__m256*-ot egyszerre teljesítmény csökkenés nélkül. Az AVX új utasításkészlettel rendelkezik a *__m128*-hoz, VEX előtagokkal. Ezeknek az új VEX-utasításoknak nem okoz problémát a *__m256* utasításokkal való kombinálása. Az teljesítmény büntetés akkor jelentkezik, ha a nem VEX *__m128* utasításokat *__m256* utasításokkal kombinálják. Ez akkor fordul elő, ha régi SSE-könyvtárakat használunk, amelyet új AVX-kompatibilis programokhoz linkelünk.

A büntetések elkerülése érdekében a fordító automatikusan hozzáadhat extra hívásokat a kódhoz. A *-mvzeroupper* fordító paraméter lehetővé teszi, hogy fordítás időben *VZEROUPPER* (törli a felső 128 bitet) vagy a *VZEROALL* (törli az összes YMM regisztert) hívások bekerüljenek a kódba. ettől függetlenül a programozó ezt manuálisan is megteheti. Ha nem használunk külső SSE-könyvtárakat, és biztosak vagyunk benne, hogy minden kódunk VEX-kompatibilis, és engedélyezett AVX-bővítményekkel lett lefordítva, akkor utasíthatjuk a fordítót, hogy kerülje a *VZEROUPPER* hívások

hozzáadását a következő parancsokkal: *-mno-vzeroupper*

Adat betöltés, kiürítés és keverés

Az adatok oda-vissza mozgatása az AVX-regiszterekből költséges lehet. Bizonyos esetekben, ha vannak lineáris struktúrákban tárolt adatok, ezeknek az adatoknak az AVX vektorokba való mozgatása, bizonyos műveletek végrehajtása és az adatok visszahozása a regiszterekből költségesebb, mint egyszerű lineáris számítások elvégzése. Tehát a programozóknak figyelembe kell venni és számolni kell az adatbetöltés és kivétel költségeivel. Bizonyos esetekben ez szűk keresztmetszetté is válhat.

5. Teszt eredmények

Az SIMD alapú implementáció nagymértékben növelheti egy program számítási hatékonyságát. Természetesen nem lehet univerzális kijelentéseket tenni, hiszen a "nyereség" függ az adott program jellegétől (CPU intenzív vagy nem), valamint a SIMD megvalósítás miként tjétől is. Nem minden számításnak készíthető el ugyanolyan sikerességgel a SIMD átirata.

Éppen ezért a SIMD megoldások hatékonyságának tesztelésére olyan alapvető matematikai feladatokat választottunk, amelyek nagy valószínűséggel a legtöbb CPU intenzív alkalmazásban megjelennek. A hatékonyság mérésére négy darab tesztesetet készítettünk elő, melyek három különböző módszerrel lettek elkészítve: hagyományos implementáció (naiv), SSE és AVX változatok.

A megvalósított tesztesetek az alábbiak:

- Skaláris szorzás
- Vektor hosszának kiszámítása
- Vektor skalárral való szorzása
- Vektor egy másik vektorral való szorzása

A programok elkészítéséhez a C++ nyelvet és a GCC 11.1.0 fordítót használtuk, a méréseket pedig egy Intel(R) Core(TM) i7-9700 CPU @ 3.00GHz CPU-val végeztük el. Minden tesztesetet 400.000 darab 4 elemű vektoron (pl.: Vector4(4,3,5,1)) hajtottuk végre. A táblázatban szereplő végső eredmények öt darab futtatás eredményének átlagaként kerültek megállapításra. A mérések Linux operációs rendszer alatt készültek, melyek eredményei nanoszekundumban értendők.

Táblázat 2. Futtatási eredmények

	Naiv	**SSE**	**AVX**	**Teljesítmény növekedés - SSE**	**Teljesítmény növekedés - AVX**
Skaláris szorzat	3467776	2033760	1423108	41.35 %	30 %
Vektor hosszának számítása	2500097	2128189	1742673	14.87 %	18.11 %
Vektor szorzása skalárral	4777252	3873024	267869	18.92 %	6.92 %
Vektor szorzása vektorral	4539375	2920104	1359712	35.67%	53.43 %

Az eredmények egyértelműen alátámasztják a SIMD változatok előnyeit. A teljesítménynövekedés SSE és AVX esetén is számottevő, melyek megfeleltek a

várakozásoknak. Hozzá kell tenni azonban, hogy a SIMD átalakítás, főként az AVX esetében nem minden esetben triviális. Egy sikeres SIMD átíráshoz megfelelő adatelőkészítés is szükséges. Főleg az AVX esetében, hiszen ott már meglehetősen nagy regiszterekkel dolgozhatunk. Ha azokat nem töltjük fel megfelelően, akkor a sebességnövekedés elmaradhat. Míg az SSE esetében a négyelemű vektor minden eleme „természetesen" belefér a *__m128* regiszterbe, addig az AVX esetében ez már nem mondható el a *__m256* regiszterről. Így az AVX transzformáció nemcsak formális kódmódosítást igényelt, hanem a ciklusok átstrukturálását is.

Végül nem szabad megfeledkezni arról a tényről sem, hogy a témában elérhető anyagok mennyisége lényegesen kevesebb azok számára, akik ezzel az optimalizálási szinttel szeretnének foglalkozni.

6. Összefoglalás

A valós életben a programozók csak egy kis százaléka találkozik a CPU kiterjesztésekkel. Egy átlagos alkalmazás készítése gyakran nem igényelni az ilyen szintű optimalizációt. Mindezek mellett a mai trendeknek megfelelő magasabb szintű nyelveken való alkalmazásfejlesztés nem teszik lehetővé a modern CPU-k kiterjesztett utasításkészletének közvetlen használatát. Természetesen a nyelvek fordítói ezt megpróbálják automatizáltan elvégezni, de emberi intelligencia nélkül a sok esetben ez nem végezhető el maradéktalanul. A teljesítmény elmaradhat a lehetséges maximumtól.

Az SSE/AVX/Neon alapú kiterjesztésekkel nagymértékben javíthatók a számítási teljesítmények. Gondoljunk csak a korai számítógépes játékokra, amelyek elképesztő teljesítményt voltak képesek elérni (csak MMX és SSE-vel) az akkori lassú CPU-kon is. Ennek azonban ára van. A programozási feladat megoldása nehezebb lesz, az SSE/AVX/Neon kód módosítások magasabb programozói tudást és alacsonyabb szintű nyelvet igényelnek, amelyek csökkenthetik a cég produktivitását. Ez pedig üzleti szempontból nem illik a mai pörgő és haszonorientált világba. Ma már elfogadható kompromisszum a vállalatoknak, hogy az adott programhoz erősebb hardvert javasolnak, mintsem jelentős időt töltsenek a szoftverük optimalizálásával.

Irodalomjegyzék

[1] João M. P. Cardoso, José Gabriel F. Coutinho, Pedro C. Diniz (2017). *Embedded Computing for High Performance*, Efficient Mapping of Computations Using Customization, Code Transformations and Compilation, Pages 17-56.

[2] Intel® 64 and IA-32 Architectures Software Developer Manuals. Published on October 12, 2016, updated May 18, 2018. Available: https://software.intel.com/en-us/articles/intel-sdm [Megtekintés: 06-január-2022].

[3] David Padua (2011). *Encyclopedia of Parallel Computing*, Springer-Verlag New York Inc.

[4] SSE & AVX Vectorization (2022), https://www.codingame.com/playgrounds/283/sse-avx-vectorization/sse-and-avx-usage

[5] Dan C. Marinescu (2018), Cloud Computing, Theory and Practice, Theory and Practice (Second Edition), Morgan Kaufmann

[6] Intel Corporation (2011), Intel® Advanced Vector Extensions Programming Reference, http://www.intel.com

[7] Intel Corporation (2014), Optimizing Performance with Intel® Advanced Vector Extensions, WHITE PAPER, Intel® Advanced Vector Extensions Processor Performance

[8] Hwancheol Jeong, Sunghoon Kim, Weonjong Lee, Seok-Ho Myung (2012), Performance of SSE and AVX Instruction Sets, 30th International Symposium on Lattice Field Theory (Lattice 2012)

[9] Agner, Software optimization resources. C++ and assembly. Windows, Linux, BSD, Mac OS X. URL http://www.agner.org/optimize/

[10] Hossein Amiri, Asadollah Shahbahrami (2020), SIMD programming using Intel vector extensions, Journal of Parallel and Distributed Computing, Volume 135, pp. 83-100.
[11] Hossein Amiri, Asadollah Shahbahrami, Angela Pohl, Ben Juurlink (2018), Performance evaluation of implicit and explicit SIMDization, Microprocessors and Microsystems, Volume 63, pp 158-168.
[12] AMD (2000), 3DNow! Technology Manual, Tech. rep.
[13] Peleg A., Weiser U. (1996), MMX technology extension to the intel architecture**,** IEEE Micro, 16 (4) (1996), pp. 42-50,
[14] Péter Mileff, Judit Dudra (2014), Advanced 2D Rasterization on Modern CPUs, Applied Information Science, Engineering and Technology: Selected Topics from the Field of Production Information Engineering and IT for Manufacturing: Theory and Practice, Series: Topics in Intelligent Engineering and Informatics, Vol. 7, Chapter 5, Springer International publishing, pp. 63-79.