

CPU چوبیرون رود، GPU در آید!

هومن سیاری

Sayyari@ComputerNews.ir

استفاده از کارت گرافیکی برای پردازش به جای پردازنده! راحت‌تر بگوییم، استفاده از GPU به جای CPU! آیا کارت‌های گرافیکی، پردازنده‌ها را حذف خواهند کرد؟ مطالب و آزمایشات ارائه شده در این مقاله، حول محور فوق دور می‌زند

برای CUDA هستند. CUDA با تمامی GPUهای سری ۸ به بعد شرکت nVIDIA در هر سه خط تولید Quadro، GeForce و Tesla کُمار می‌کند. nVIDIA تصریح می‌کند که تمامی برنامه‌هایی که برای GeForce سری ۸ نوشته شده‌اند، همچنان بدون نیاز به تغییر روی کارت‌های جدیدتر اجرا خواهند شد. CUDA همچنین امکان دسترسی برنامه‌نویسان به مجموعه دستورالعمل‌های Native و اجزای حافظه در پردازش موازی را نیز فراهم می‌کند که این امر توانایی برنامه‌نویس را در کنترل سخت‌افزار بسیار بالا می‌برد. بنابراین با استفاده از CUDA، معماری GPUها هم مثل CPUها باز می‌شود، گرچه GPUها برخلاف CPUها دارای یک معماری "بسیار-هسته‌ای" موازی هستند که طی آن هسته‌ها توانایی پردازش هزاران Thread را به طور همزمان دارند. بنابراین اگر برنامه‌ای منطبق با این معماری باشد، می‌تواند راندمانی بسیار بالاتر از اجرا بر روی CPU را به ارمغان بیاورد.

بیش از ۱۰۰ میلیون GPU فروخته شده با قابلیت CUDA در سراسر دنیا، بسیاری از برنامه‌نویسان با استفاده از کیت SDK (Software Development Kit) برنامه‌نویسی روی GPU که توسط nVIDIA فراهم شده است، در حال نوشتن برنامه‌های متفاوتی از سطح خانگی تا حرفه‌ای از پردازش‌های صوتی و تصویری گرفته تا شبیه‌سازی‌های فیزیکی، اکتشاف نفت و گاز، طراحی محصول، تصاویر پزشکی و تحقیقات علمی هستند. بسیاری از کاربردهای فوق حداقل ۲۵۶ مگابایت حافظه اختصاصی گرافیکی نیاز دارند که امروزه این مقدار حافظه را روی تمامی کارت‌های گرافیکی می‌توان یافت. در دنیای بازی‌های کامپیوتری، کارت‌های گرافیکی علاوه بر رندر تصاویر گرافیکی، برای محاسبات فیزیکی بازی (افکت‌های فیزیکی مثل دود، آتش، حرکت آب، شن و ...)

و امکان انجام برخی از پردازش‌های CPU را توسط کارت‌های گرافیکی خود میسر کرده‌اند. nVIDIA نام فناوری خود را CUDA گذاشته است و ATI هم نام Stream را انتخاب کرده است. باید دید که آیا GPUها موفق می‌شوند CPUها را از دور خارج کنند؟

nVIDIA CUDA

CUDA که مخفف عبارت Compute Unified Device Architecture است، یک معماری جدید پردازش موازی است که توسط nVIDIA ابداع شده است.

CUDA موتور پردازشی در GPUهای nVIDIA است که توسط برنامه‌نویسان و در زبان برنامه‌نویسی خاص خود قابل دسترسی است. برنامه‌نویسان در نسخه خاصی از زبان قدرتمند C که دارای ضمیمه (nVIDIA C with nVIDIA extensions) است، برنامه‌های خود را می‌نویسند و بعد از کامپایل قادرند آنها را روی GPU اجرا کنند. البته به زودی با سایر زبان‌های برنامه‌نویسی مثل C++ و Fortran هم می‌توان روی GPU برنامه نوشت.


آخرین نسخه درایورها، همگی دارای تمامی اجزای مورد نیاز

مدتی است که زمزمه استفاده از GPU به جای CPU نقل بسیاری از سایت‌ها و پیش‌قراولان سخت‌افزار شده است. دلیل آن هم بدیهی است. امروزه پیشرفته‌ترین پردازنده‌های دسکتاپ اینتل یا AMD فقط ۴ هسته دارند در حالی که کارت‌های گرافیکی موجود صدها هسته دارند. پس اگر بشود پردازش‌های رایج یا حتی تنها بخشی از آنها را توسط GPU انجام داد، اولاً راندمان بسیار بالایی به دست می‌آید و ثانیاً بار پردازشی از دوش CPU برداشته شده و امکان انجام پردازش‌های دیگر توسط آن فراهم می‌شود. جنگ GPU بین ATI و nVIDIA که از اوایل سال ۲۰۰۰ شروع شده، منجر به افزایش قدرت پردازشی GPUها شده است. به موازات این افزایش قدرت و سرعت، هر دو شرکت مذکور نیاز به افزایش کیفیت ویدیویی مخصوصاً در برنامه‌های گرافیکی سبب‌دی نیز داشتند که این امر در بحث AntiAliasing و AntiSotropic بروز کرد. اگرچه فناوری‌های عرضه شده توسط آنها در مقاطع مختلف، باعث افزایش کیفیت شده است، اما تحولی اساسی ایجاد نکرده است. اینک هر دو با فناوری جدیدی (هر چند با اسامی متفاوت) قصد انقلاب در حیطه پردازش‌های سنگین را دارند. هر دو غول گرافیکی دنیا یعنی nVIDIA و ATI (یا بهتر بگوییم AMD) این ایده را در مرحله عمل آورده‌اند



nVIDIA®

CUDA®



ATI Stream Acceleration

ATI هم با همان ایده nVIDIA اقدام به پردازش موازی توسط GPU کرده است و آن را ATI Stream Acceleration نامیده است. Stream مجموعه‌ای از فناوری‌های پیشرفته سخت‌افزاری و نرم‌افزاری است که امکان همکاری پایایی پردازنده‌های گرافیکی AMD ATI سابق را با CPU فراهم می‌کند تا بسیاری از کاربردها و مهم‌تر از همه، پردازش‌های گرافیکی با سرعت بالایی انجام شوند. در واقع AMD اکوسیستمی طراحی کرده که کارایی بالا، کاربردهای متنوع، نرم‌افزارهای خاص و ابزارهای ویژه از جمله ویژگی‌های آن است. در واقع Stream به یک گروه از مسایل، کاربردها یا پردازش‌ها اشاره می‌کند که می‌توانند به عملیات‌های موازی و مجزا شکسته شوند و به طور همزمان روی یک پردازنده اجرا شوند. این جریان‌های داده موازی وارد پردازنده می‌شوند و به صورت موازی در هسته‌های آن پردازنده اجرا شده و نتایج به صورتی قابل اتصال به هم از پردازنده خارج می‌شوند. در واقع مزیت اصلی Stream در پردازش‌های SIMD (Single Instruction Multiple Data) است.

دلیل مشکلات ساختاری کمی عدم دقت پیش می‌آید. برای راندمان بالا Threadها باید در گروه‌های حداقل ۳۲ تایی اجرا شوند در حالی که نیاز به هزارها thread است. انشعاب‌ها در کد برنامه باعث افت راندمان می‌شوند و هر ۳۲ تا thread یک مسیر اجرایی را طلب می‌کند. مدل اجرایی SIMD در زمان اجرای یک برنامه ذاتاً انشعاب‌پذیر دچار محدودیت‌های قابل توجهی می‌شود.

● GPUهای دارای CUDA فقط در تولیدات سری ۸ به بعد nVIDIA قابل پشتیبانی هستند.

تبدیل کننده Badaboom

nVIDIA در تولید نرم‌افزارهای مبتنی بر GPU پیش قدم شده و ابزاری به نام Badaboom برای تبدیل فرمت‌های مختلف فایل‌های ویدیویی به یکدیگر عرضه کرده است. nVIDIA می‌گوید Badaboom تا ۲۰ برابر سریع‌تر از سایر نرم‌افزارهای رایج تبدیل کننده عمل می‌کند. البته دوستان برنامه‌نویس می‌دانند که چرا nVIDIA تبدیل فایل‌های ویدیویی را به عنوان نمونه‌ای از کاربردهای CUDA عرضه کرده است، چرا که عمل تبدیل فرمت‌های ویدیویی بسیار مناسب برنامه‌نویسی موازی است و هیچ انشعابی در برنامه پیش نمی‌آید. البته کار عجیبی که انجام داده، این است که قیمت ۳۰ دلار را برای این نرم‌افزار تعیین کرده است. معمولاً شرکت‌ها برای توسعه یک فناوری جدید، از سودهای ناچیز چشم‌پوشی کرده و شرایط را برای معرفی بیشتر فناوری مورد نظر مساعد می‌کنند.

که اصطلاحاً PhysX نامیده می‌شوند، نیز مورد استفاده قرار می‌گیرند. CUDA همچنین برای افزایش سرعت کاربردهای غیر گرافیکی مثل محاسبات بیولوژیکی و رمزنگاری هم استفاده می‌شود.

CUDA هم APIهای سطح پایین و هم APIهای سطح بالا را فراهم کرده است. در ۱۵ فوریه ۲۰۰۷ کیت SDK مربوط به CUDA در محیط ویندوز و لینوکس ارایه شد و سپس در نسخه ۲.۰ که در تاریخ ۱۴ فوریه ۲۰۰۸ ارایه شد، MacOS هم مورد پشتیبانی قرار گرفت (شکل ۱).

مراحل پردازش CUDA در شکل ۱ به ترتیب زیر است:

- ۱- کپی داده‌ها از حافظه اصلی به حافظه GPU
- ۲- دستور انجام پردازش توسط CPU به GPU
- ۳- انجام پردازش موازی در هسته‌های GPU
- ۴- کپی نتایج از حافظه GPU به حافظه اصلی

ویژگی‌های CUDA

- استفاده از زبان C استاندارد برای نوشتن برنامه‌های پردازش موازی بر روی GPU
- کتابخانه‌های عددی استاندارد برای انجام تبدیل فوریه سریع و سابروتین‌های اصلی جبر خطی
- درایور CUDA اختصاصی برای انتقال سریع داده‌ها بین GPU و CPU
- درایور CUDA اختصاصی برای عمل متقابل با DirectX و OpenGL
- پشتیبانی از ویندوز و لینوکس و Mac OS

مزایای CUDA

- CUDA دارای چندین مزیت نسبت به روش‌های معمول پردازش توسط GPU است که در ادامه ذکر شده‌اند:
- خواندن پراکنده: کدها می‌توانند از چندین آدرس مختلف از حافظه خوانده شوند.
 - حافظه اشتراکی: CUDA می‌تواند بخشی از حافظه را بین Threadها با سرعت بالا به اشتراک بگذارد که در واقع مثل کشی عمل می‌کند که توسط کاربر کنترل می‌شود و پهنای باند بالاتری را ایجاد می‌کند.
 - دانلود و بازخوانی سریع‌تر به و از GPU
 - پشتیبانی کامل از عملیات صحیح و بیتی

محدودیت‌های CUDA

- CUDA از یک زبان C، بدون توابع بازگشتی و بدون اشاره‌گر استفاده می‌کند و یک پردازش ساده در



بروز می‌کند. چون CPU بر اساس روش SISD (Single Instruction Single Data) کار می‌کند، بنابراین در پردازش‌های موازی Stream عالی ظاهر می‌شود (شکل ۲).

برنامه‌هایی که می‌خواهند برای Stream طراحی شوند باید دو مشخصه اصلی داشته باشند:

- درجه بالایی از محاسبات ریاضی در هر واکنشی (Fetch) از حافظه
- محاسبات مستقل: انجام محاسبات روی هر واحد پردازشی بدون نیاز به بررسی یا تایید هر واحد پردازشی دیگر.

ویژگی‌های Stream عبارتند از:

- امکان اجرای برنامه‌های جدید بر روی معماری جدید
- امکان اجرای پردازش‌های موازی که با معماری GPUهای جدید مطابقت دارند
- انتقال از توابع ثابت به پای‌لاین قابل برنامه‌نویسی کاربردهای وسیع در تحقیقات و صنایع تحت عنوان GPGPU
- پشتیبانی از ۳۲۰ هسته پردازشی (واحد محاسباتی یا ALU)
- پشتیبانی از GPUهای سری R600 به بعد

مهم‌ترین مزایای Stream

مزایای سخت‌افزاری:

- انجام محاسبات ممیز شناور با دقت مضاعف
- پشتیبانی از ۲ گیگابایت حافظه اختصاصی GDDR3
- مصرف توان پایین در پردازش‌های سنگین (پردازش بیش از ۵ میلیارد عملیات ممیز شناور با یک وات توان)
- نیاز به یک کانکتور برق برای Stream
- DMA غیر همزمان (انتقال داده‌ها بدون نیاز به وقفه پردازنده)

- امکان استفاده از حافظه‌هایی با اندازه متفاوت برای نگهداری نتایج میانی
- استفاده از یک برد کوچک (فقط ۲۳.۵ سانتی‌متر)
- پشتیبانی از اینترفیس PCI Express 2.0 x16

مزایای نرم‌افزاری:

- قابل برنامه‌نویسی با محیطی شبیه C با یک کامپایلر سطح بالا
- پشتیبانی از سیستم عامل‌های ویندوز و لینوکس ۳۲ و ۶۴ بیتی

در دسامبر ۲۰۰۸ شرکت AMD با عرضه ATI Catalyst نسخه ۸.۱۲، امکان استفاده از قابلیت Stream را در کارت‌های خود فعال کرد. شرکت AMD برای تمرکز بر روی قابلیت Stream دو خط تولید جدید کارت گرافیکی به نام‌های ATI FirePro و AMD FireStream را راه‌اندازی کرد تا به صورت کاملاً حرفه‌ای کارت‌هایی طراحی کند که نهایت راندمان را براساس Stream به ارمغان بیاورد.

ATI Avivo



Avivo هم نمونه‌ای از کاربردهای قابلیت Stream است که توسط ATI برای تبدیل فرمت‌های مختلف فایل‌های ویدیویی به یکدیگر عرضه شده است. Avivo معادل Badaboom شرکت NVIDIA است. Avivo در GPUهای سری Radeon R520 به بعد ارایه شده است. Avivo برای برداشتن بار پردازشی از دوش پردازنده اصلی طراحی شده است. از جمله این بار پردازشی می‌توان عملیات رمزنگاری یا رمزگشایی فایل‌های ویدیویی (Video Decoding/Encoding) و پردازش‌های محاسباتی سنگین را نام برد. اگر با سیستمی

که دارای یک GPU با قابلیت Avivo است، اقدام به پخش و کدگذاری یک فایل ویدیویی توسط نرم‌افزار خاص Avivo کنید، می‌بینید که درصد استفاده از پردازنده اصلی بسیار کمتر از حالتی است که از نرم‌افزارهای رایج استفاده می‌کنید. نکته جالب آنکه ATI این نرم‌افزار را برخلاف NVIDIA به صورت رایگان عرضه می‌کند.

تست Avivo

ما در لابراتوار تصمیم گرفتیم که به ارزیابی قدرت GPU در کاربردهایی که تا به حال توسط CPU انجام می‌شده است، بپردازیم.


معمولاً شرکت‌های ارایه کننده فناوری‌های جدید کمی در مورد نوآوری‌های خود اغراق می‌کنند و ATI و NVIDIA هم از این قاعده مستثنی نیستند. هر دو شرکت ادعا می‌کنند که مثلاً در مقوله تبدیل فرمت‌های مختلف فایل‌های ویدیویی به یکدیگر، حدود ۲۰ برابر نسبت به نرم‌افزارهای رایج که از CPU استفاده می‌کنند، سریع‌تر عمل می‌کنند. البته تنها قابلیتی که فعلاً می‌توان تست کرد، همان تبدیل فایل‌های ویدیویی است، چرا که نرم‌افزار آن توسط شرکت‌های فوق ارایه شده است.

تست با فرمت‌های مختلف

ما برای تست از یک فایل ۲۰۰ مگابایتی با فرمت MPEG2 و یک فایل یک گیگابایتی با فرمت VOB (فرمت DVD) استفاده کردیم و آنها را به فرمت‌های مختلف تبدیل کردیم. هر تبدیل را یکبار با نرم‌افزار ATI Avivo و یکبار با نرم‌افزار Main Concept Reference تکرار کردیم و نهایت دقت را در یکسان بودن تمامی تنظیمات تبدیل انجام دادیم. بدیهی است که برای کدینگ ATI Avivo از GPU و Main Concept Reference از CPU استفاده می‌کنند. نتایج آزمایشات در شکل‌های ۳ تا ۶ نشان داده شده است.

مشخصات سخت‌افزاری	
CPU	Intel Core2Duo E8200 2.66 GHz 6MB cache
Graphic Card	SAPPHIRE Radeon HD4890
Motherboard	GIGABYTE GA-EX38-DS4
RAM	2x1GB DDR2 Corsair Dominator 1066
HARD	320GB Western Digital WD3200AAJS
DVD-RW	SAMSUNG SH-S203
Monitor	SAMSUNG SyncMaster 2032BW
Power	Green GP580B 580W
مشخصات نرم‌افزاری	
OS	Windows Vista Ultimate SP1 32bit
Driver	ATI Catalyst 9.7 Full
Applications	ATI Avivo 9.7 Main Concept Reference 1.6.34425

جدول ۱: مشخصات سیستم تست



شکل ۲: مراحل تبدیل فرمت ویدیویی در ATI Stream

کلام پایانی

تا چندی پیش در جوامع علمی مطرح بود که پردازنده‌ای طراحی شود که دارای GPU هم باشد و برای کاربردهای سبک گرافیکی مورد استفاده قرار گیرد، اما حالا قضیه برعکس شده است. GPUها کار پردازنده را انجام می‌دهند.

هر چند GPUها فعلاً تمامی پردازش‌های CPU را نمی‌توانند انجام دهند، اما دورنمای این فناوری چیز دیگری را نشان می‌دهد. آری، شمارش معکوس برای به تاریخ پیوستن CPU شروع شده است. البته نگارنده معتقد است که GPU جای CPU را نمی‌گیرد (به دلیل تفاوت معماری آنها و کاربردهای متفاوت آنها) بلکه GPU نقش پردازنده کمکی یا Coprocessor را بازی خواهد کرد، با این تفاوت که این پردازنده کمکی در بسیاری از پردازش‌ها از پردازنده اصلی قوی‌تر عمل می‌کند! ■

تشکر ویژه

با تشکر از شرکت محترم فونیران که کارت گرافیک مورد استفاده در این مقاله را در اختیار لایبراتورار رایانه‌خبر قرار دادند.

شماره تلفن: ۸۸۷۲۸۷۲۲
www.phoniran.com

پردازش به وجود می‌آید و دیگر چیزی به عنوان CPU وجود خارجی نخواهد داشت. البته مشروط بر اینکه برنامه‌ها قادر به ارسال تعداد زیادی دستورالعمل به GPU باشند و در سطح بسیار بالایی از پردازش موازی پشتیبانی کنند. اگر قصد خرید کارت گرافیکی دارید، حتماً مدلی که CUDA یا AVIVO را پشتیبانی می‌کند، خریداری کنید. هر چند با خرید این نوع کارت‌ها به تنهایی امکان استفاده از قابلیت فوق را ندارید، اما می‌توانید از برنامه‌هایی که برنامه‌نویسان و تولیدکنندگان براساس این قابلیت نوشته‌اند، استفاده کنید و لذت سرعت بالا را حس کنید. مثلاً برنامه‌هایی که برای تبدیل فرمت‌های مختلف ویدیویی به یکدیگر وجود دارند، با استفاده از CPU این کار را انجام می‌دهند، حال آنکه برنامه‌های دیگری براساس CUDA یا AVIVO نوشته شده‌اند که همان کار را بدون استفاده از CPU چندین برابر سریع‌تر انجام می‌دهند. ضمناً دوستداران بازی هم می‌توانند بازی‌های جدیدتر را که براساس قابلیت فوق عرضه می‌شوند، بسیار طبیعی‌تر و روان‌تر بازی کنند.

به طور خلاصه می‌توان گفت که استفاده از GPU به جای CPU دو مزیت اصلی دارد:

- سرعت بسیار بالاتر در انجام محاسبات
- آزاد شدن CPU و امکان استفاده از آن در پردازش‌های دیگر

پس چرا راندمان، ۲۰ برابر نشد؟

همانطور که قبلاً اشاره شد، ATI و nVIDIA مدعی هستند که در تبدیل فرمت‌های مختلف فایل‌های ویدیویی به یکدیگر، حدود ۲۰ برابر نسبت به نرم‌افزارهای رایج که از CPU استفاده می‌کنند، سریع‌تر عمل می‌کنند. اما آزمایشات ما این را نشان نمی‌دهد!


البته با کمی تعمق می‌توان فهمید که چرا این‌گونه نشده است. آنها اختلاف قوی‌ترین GPU را با ضعیف‌ترین CPU در نظر می‌گیرند. بنابراین اگر از CPU قوی‌تر و یا از GPU ضعیف‌تر استفاده کنیم، این اختلاف کاهش می‌یابد، هر چند همیشه و در همه حال GPU بهتر از CPU عمل می‌کند. در سیستم تست ما هم گرچه از کارت گرافیک خیلی خوبی استفاده کردیم، اما پردازنده خوبی هم داشتیم که به طبع مانع از ایجاد اختلاف فاحش می‌شد.

ضمناً آنها کدینگ را در نظر می‌گیرند که بیشترین اختلاف را در GPU نسبت به CPU دارد (کدینگ‌های مختلف، دارای نسبت‌های متفاوتی از اختلاف بین GPU و CPU هستند).

نتیجه

استفاده از GPU به جای CPU علی‌رغم تمام محدودیت‌هایی که دارد، سرعت و راندمان بالایی را به ارمغان می‌آورد. اگر بتوان روزی تمامی پردازش‌های CPU را توسط GPU انجام داد، تحولی شگرف در سرعت

تبدیل فایل یک گیگابایتی با فرمت VOB به فرمت‌های مختلف



تبدیل فایل ۲۰۰ مگابایتی با فرمت MPEG 2 به فرمت‌های مختلف

