

رهیافت توماس موازی در دینامیک سیالات محاسباتی به کمک پردازنده‌های گرافیکی – جریان درون حفره*

(یادداشت پژوهشی)

پوریا اکبرزاده^(۱) حسین محمودی داریان^(۲) محسن نظری^(۳) میلاد سوری^(۴)

چکیده در این مقاله سه الگوریتم کاهش متناوب، کاهش متناوب موازی و رهیافت توماس موازی برای حل دستگاه معادلات سه‌قطربعدی به کمک پردازنده‌های گرافیکی معرفی و اثر دسترسی هم‌مکان و غیره‌هم‌مکان به حافظه سراسری مورد بحث قرار گرفته است. برای ارزیابی توانایی این الگوریتم‌ها، نتایج شبیه‌سازی جریان درون حفره (یک مورد مطالعاتی) با نتایج الگوریتم توماس کلاسیک اجرای شده روی پردازنده مرکزی مقایسه شده است. بیشینه افزایش سرعت مشاهده شده در سه الگوریتم مذکور (پردازنده گرافیکی) در برابر الگوریتم توماس کلاسیک (پردازنده مرکزی) به ترتیب حاصل شد ۴/۴، ۵/۲ و ۳۸/۴۵ می‌باشد. همچنین نشان داده شده است که با دسترسی هم‌مکان، افزایش سرعت حاصل شود.

واژه‌های کلیدی رهیافت توماس موازی؛ پردازش موازی؛ دستگاه معادلات سه‌قطربعدی؛ پردازنده گرافیکی؛ الگوریتم کاهش متناوب.

Parallel Thomas Approach in Computational Fluid Dynamics with GPUs– Lid-driven Cavity

P. Akbarzadeh H. Mahmoodi Darian M. Nazari M. Souri

Abstract In this paper three algorithms of Cyclic-Reduction, Parallel-Cyclic-Reduction and Parallel-Thomas are introduced to solve the Tridiagonal system of equations using GPUs and the effect of coalesced-memory-access and uncoalesced-memory-access to global memory are studied. To assess the ability of these algorithms, as a case-study the simulation of the lid-driven cavity flow have been compared to the results of Runtimes and physical parameters of the classical Thomas algorithm, executed on CPU. The maximum speed-up of these algorithms against CPU runtime is about 4.4x, 5.2x and 38.5x, respectively. Also, approximately a 2x speed-up achieved in coalesced-memory access on GPU.

Key Words Parallel Thomas approach; Parallel Processing; Tridiagonal system of equations; Graphic Processor; Cyclic Reduction algorithm

*تاریخ دریافت مقاله ۹۴/۴/۲۳ و تاریخ پذیرش آن ۹۴/۹/۱۸ می‌باشد.

(۱) نویسنده مسئول: دانشیار، مهندسی مکانیک، دانشگاه شهرورد. p.akbarzadeh@shahroodut.ac.ir

(۲) استادیار، مهندسی مکانیک، دانشگاه تهران.

(۳) دانشیار، مهندسی مکانیک، دانشگاه شهرورد.

(۴) دانشجوی کارشناسی ارشد، مهندسی مکانیک، دانشگاه شهرورد.

مقدمه

هستند که به دنبال تقویت عملکرد کاربرد پردازنده‌های گرافیکی در حل مسائل مختلف می‌باشند. ژانگ و همکاران [2] در سال ۲۰۰۹ ابتدا روی قابلیت اجرای الگوریتم‌های کاهش متناوب و کاهش متناوب موازی روی پردازنده‌های گرافیکی بحث کرده‌اند. سپس یک روش ترکیبی از الگوریتم‌های معرفی شده را پیشنهاد و عملکرد هر الگوریتم را روی حل ماتریس‌های سه‌قطري آزمایش کردند. لازم به توضیح است که الگوریتم کاهش متناوب مشکل تداخل حافظه (Bank Conflict) در حافظه مشترک کارت گرافیکی را دارد و همچنین برای به کار بردن الگوریتم‌های کاهش متناوب و کاهش متناوب موازی اندازه دستگاه سه‌قطري حتماً باید محدود به 2^n باشد. در سال ۲۰۱۱ گودک و استروودکا [3] در مورد محدودیت ابعاد ماتریس در حافظه مشترک کارت گرافیکی بحث کرده‌اند. آنها نشان دادند که انتقال پیاپی اطلاعات بین حافظه مشترک و حافظه سراسری کارت گرافیکی بر عملکرد الگوریتم تأثیر می‌گذارد. در سال ۲۰۱۱ دیویدسون و همکاران [4] یک الگوریتم چندمرحله‌ای برای حل دستگاه معادلات سه‌قطري با پردازنده گرافیکی پیشنهاد کردند که نتایج کار آنها نشان می‌داد سرعت الگوریتم پیشنهادی تا پنج برابر افزایش سرعت در مقابل الگوریتم‌های حل غیرموازی دستگاه معادلات سه‌قطري به دست آورده است. اگلوف [5] الگوریتم کاهش متناوب موازی را برای حل دستگاه معادلات سه قطري با اندازه بسیار بزرگ در معادلات دیفرانسیل با مشتق‌های جزئی به کار برد و به دلیل استفاده از حافظه سراسری، 6^0 درصد کاهش سرعت را گزارش داد. کیم و همکاران [6] به دلیل محدودیت در حافظه مشترک، پیشنهاد دادند که برای دستگاه‌های بزرگ ابتدا آنها را توسط الگوریتم کاهش متناوب موازی به دستگاه‌های کوچک‌تر تبدیل کنند، سپس این دستگاه معادلات مجزا توسط الگوریتم توامس حل شوند. توکن و همکاران [7] به بحث و بررسی روی

در سال‌های اخیر با توجه به نیاز جوامع علمی به بررسی مسائل مختلف با پیچیدگی بیشتر، نیاز به کامپیوترهایی با سرعت و حافظه بیشتر احساس می‌شد، بنابراین محققان به استفاده از پردازنده‌های مرکزی (Central Processor Unit, CPU) با سرعت بیشتر روی آوردن. در کنار این رویکرد، امروزه بهره‌گیری از پردازنده‌های گرافیکی (Graphic Processor Units, GPU) نیز، به دلیل عملکرد بسیار بالا و پهنای باند (Memory Band Width) حافظه زیاد، جایگاه ویژه‌ای را در شبیه‌سازی پدیده‌ها و محاسبات علمی به خود اختصاص داده‌اند. ساختار معماری پردازنده‌های گرافیکی به گونه‌ای است که می‌تواند در زمانی کوتاه یک دستور العمل محاسباتی را روی تعداد زیادی داده به صورت موازی و هم‌زمان اجرا نماید. روند روبه رشد استفاده از پردازنده‌های گرافیکی به عنوان شتاب‌دهنده محاسبات به گونه‌ای است که ابرکامپیوترهای برتر حال حاضر دنیا از قدرت پردازنده‌های گرافیکی بهره می‌برند [1]. در بسیاری از مسائل مهندسی، گسسته‌سازی معادلات حاکم منجر به تشکیل یک دستگاه معادلات سه‌قطري می‌شود که حل سریع این دستگاه معادلات یک موضوع چالش‌برانگیز در دینامیک سیالات محاسباتی محسوب می‌گردد. یکی از روش‌های قدیمی اما رایج و پرسرعت برای حل دستگاه معادلات سه‌قطري، الگوریتم توماس است که بر مبنای روش حذفی گوس می‌باشد. از آنجاکه الگوریتم این روش یک الگوریتم ترتیبی است، بنابراین الگوریتم‌های جایگزینی برای حل معادلات سه‌قطري با رویکرد پردازش موازی در پردازنده‌های گرافیکی نظیر کاهش متناوب (Cyclic Reduction) و کاهش متناوب موازی (Parallel Cyclic Reduction) معروف شده‌اند. این الگوریتم‌ها و نظایر آنها که به همین منظور ابداع شده‌اند (مانند الگوریتم‌های موجود در مرجع [2]) ابزارهای مناسبی برای بسیاری از محققان

الگوریتم‌های کاهش متناوب، کاهش متناوب موازی و رهیافت توماس موازی برای حل استفاده شده‌اند. نتایج حاصل از حل مسئله جریان درون حفره توسط الگوریتم‌های موازی با نتایج مرجع [11] مقایسه شده و از صحت نتایج اطمینان حاصل شده است. درنهایت زمان حل تمام روش‌های حل اندازه‌گیری و با هم مقایسه شده‌اند. حداکثر افزایش سرعتی که الگوریتم‌های کاهش متناوب، کاهش متناوب موازی و رهیافت توماس موازی اجراسده در پردازنده گرافیکی در برابر الگوریتم توماس کلاسیک از خود نشان می‌دهند به ترتیب $\frac{4}{4}$, $\frac{5}{2}$ و $\frac{38}{45}$ می‌باشد. هم‌چنین در این تحقیق، اثر دسترسی هم‌مکان و غیر هم‌مکان به حافظه سراسری مورد بررسی قرار گرفته و نشان داده شده است که با دسترسی هم‌مکان، افزایش سرعت قابل توجهی (حدوداً دو برابر) برای پردازنده گرافیکی حاصل می‌شود.

پردازش موازی در پردازنده‌های گرافیکی

به دلیل موازی بودن ذاتی معماری پردازنده‌های گرافیکی، در سال ۲۰۰۶ سازندگان این تراشه‌ها این ایده را ارائه دادند که اگر پردازنده‌های گرافیکی برای انجام محاسبات پیچیده وضوح تصویر توانا است، دلیل و مانع وجود ندارد که در محاسبات عددی و علمی دیگر نیز کاربرد نداشته باشند. این تفکر باعث ایجاد مفهوم پردازنده‌های گرافیکی همه‌منظوره شد. امروزه رویکردهای مختلفی برای استفاده از پردازنده‌های گرافیکی همه‌منظوره تعریف شده است که هر یک به ابزارهایی برای ارتباط کاربر و پردازنده (از جمله میان‌افزار کودا (CUDA) و اپن‌سی‌ال (OPENCL) و غیره) نیاز دارد. در واقع این ابزارها چهارچوبی هستند که راه استفاده از پردازنده‌های گرافیکی را برای محاسباتی که ارتباطی با نمایش گرافیکی ندارند هموار می‌سازند. در حال حاضر میان‌افزار کودا پرکاربردترین

شبیه‌سازی جریان توسط معادلات مرتبه بالا و حل آن به کمک پردازنده‌های گرافیکی پرداختند. آنها نشان دادند که عملکرد مؤثر یک الگوریتم پردازش موازی برای شبیه‌سازی عددی مرتبه بالا از نظر سرعت حل، بستگی زیادی به سرعت حلگر دستگاه سه‌قطري دارد. در سال ۲۰۱۲ اصفهانیان و همکاران [8] با پیاده‌سازی روش‌های مرتبه بالا کارایی پردازنده گرافیکی را برای حل معادلات هذلولوی، بررسی کردند. اصفهانیان و همکاران [9] در سال ۲۰۱۳ با به کار بستن الگوریتم کاهش متناوب بهینه شده به حل و شبیه‌سازی جریان روی استوانه و ایرفویل در دو و سه بعد پرداختند و به افزایش سرعت حل $\frac{1}{9}$ تا $\frac{15}{2}$ برابر در دو بعد و $\frac{6}{4}$ تا $\frac{20}{3}$ برابر در سه بعد دست یافتند. در سال ۲۰۱۴ محمودی داریان و همکاران [10] نیز به بررسی و حل معادلات اویلر با کمک پردازنده گرافیکی پرداختند، این ارزیابی توسط دو نوع پردازنده گرافیکی مختلف انجام شد و به حداکثر افزایش سرعت ۱۰۵ برابری نسبت به پردازنده مرکزی دست یافتند.

در این مقاله با توجه به محدودیت الگوریتم‌های معرفی شده در مورد اندازه دستگاه سه‌قطري (حتماً اندازه دستگاه باید 2^n باشد) از روشی به نام رهیافت توماس موازی برای حل این دسته از دستگاه معادلات استفاده شده است. این رهیافت که در قالب یک گزارش کوتاه نمایشی - اسلامیدنما (Powerpoint) و بدون ارائه جزئیات توسط ساختار نیخ (presentation) و همکارانش در سال ۲۰۰۹ در پایگاه (Sakharnykh) اینترنتی شرکت انویدیا (Nvidia) قرار داده شده است، چندین دستگاه سه‌قطري را با الگوریتم توماس به طور موازی و مستقل از هم حل می‌کند. برای مقایسه سرعت و دقیقت حل این الگوریتم‌ها مسئله جریان درون حفره، توسط روش تفاضل محدود، شبیه‌سازی شده است. معادلات حاکم گسترشده و این معادلات به شکل سه‌قطري درآمده و سپس با الگوریتم توماس کلاسیک روی پردازنده مرکزی حل شده‌اند. پس از آن

گرافیکی به پردازنده مرکزی میزبان (Host) و به پردازنده گرافیکی دستگاه (Device) می‌گویند در شکل (۲) ساختار حافظه دستگاه و میزبان مشخص هستند. هر نخ محاسباتی حافظه ثباتی (Register) دارد که فقط برای همان نخ محاسباتی قابل دسترس است اما حافظه مشترک (Shared-Memory) برای تمام نخهای داخل یک بلوک قابل دسترس هستند. حافظه سراسری و ثابت هم توسط نخهای تمام بلوک‌ها قابل دسترسی هستند. میزبان هم می‌تواند داده‌ها را از این حافظه‌ها دریافت یا به آن‌ها ارسال کند. میزبان نیز حافظه مجازی دارد که نخها به آن دسترسی مستقیم ندارند. اصولاً برنامه‌نویسی باکمک پردازنده‌های گرافیکی به این صورت است که دستورات توسط پردازنده مرکزی اجرا می‌شوند و در قسمت‌هایی که به قدرت پردازشی بالایی احتیاج است، توسط کرنل‌ها پردازنده گرافیکی وارد جریان محاسبات می‌شود، پس از اجرای دستورات دوباره پردازنده مرکزی ادامه دستورات را اجرا می‌کند و این روند تا پایان برنامه ادامه پیدا می‌کند. به این رویکرد، در اصطلاح محاسبات ناهمگن (Heterogeneous Computations) می‌گویند (شکل ۱). در پردازش موازی توسط پردازنده‌های گرافیکی علاوه بر قدرت و مشخصات فنی پردازنده‌های گرافیکی، عوامل مختلفی بر افزایش بازده پردازش و کاهش زمان حل مؤثر هستند؛ از جمله دسترسی هم‌مکان به حافظه سراسری (Coalesced Memory Access)، معطل نماندن نخهای محاسباتی در طول پردازش و درگیر بودن آنها و استفاده درست از حافظه مشترک که در بخش‌های بعدی به تفصیل به آنها پرداخته خواهد شد.

روش‌های حل دستگاه معادلات سه‌قطري

یک حلگر دستگاه معادلات سه‌قطري، الگوريتمی است که بردار مجهولات x را در $Ax = d$ می‌يابد، که ماتریس ضرایب با سه قطر غيرصفر و d برداری با

ابزار برنامه‌نویسی بر پایه پردازنده گرافیکی است. کودا یک محیط نرم‌افزاری برای محاسبات موازی و مقیاس‌پذیر است که بر پایه زبان C/C++ طراحی شده است. این میان‌افزار مختص پردازنده‌های ساخته شده توسط شرکت انویدیا (Nvidia) می‌باشد.

معماری یک پردازنده گرافیکی با یک پردازنده مرکزی تفاوت دارد. پردازنده گرافیکی ترانزیستورهای بیشتری نسبت به پردازنده‌های مرکزی دارد که این ترانزیستورها مسئول محاسبات هستند، اما در مورد واحدهای کنترل جریان برنامه و واحد منطق و همچنین از نظر حافظه درونی نسبت به پردازنده‌های مرکزی ضعیف‌تر می‌باشند. پردازنده‌های گرافیکی، درواقع پردازشگرهای موازی هستند که از سامانه‌های چندنخی (Multi Threads) عظیمی استفاده می‌کنند. برای تحقق این امر هر پردازنده گرافیکی دارای تعدادی چندپردازنده می‌باشد که هر چندپردازنده دارای چندین هسته کودا (CUDA Core) است. هر هسته کودا برای پردازش برنامه و اجرای یک نخ محاسباتی (Computational Thread) اختصاص داده می‌شود. یک نخ محاسباتی یک واحد کوچک نرم‌افزاری و درواقع کوچک‌ترین واحد از دستورات در یک برنامه کامپیوتری است. در مقابل هسته کودا یک واحد کوچک سخت‌افزاری است که ترکیب این دو پردازش موازی را شکل می‌دهد. مجموعه دستورات اجرایی در پردازنده‌های گرافیکی به نام کرنل (Kernel) شناخته می‌شوند که همانند توابع در زبان‌های معمول برنامه‌نویسی هستند با این تفاوت که کرنل‌ها وقتی اجرا می‌شوند هر دستور را یک نخ محاسباتی به صورت جداگانه (موازی) اجرا می‌کند. در ساختار پردازش موازی با پردازنده‌های گرافیکی، نخهای محاسباتی در واحدهایی به نام بلوک (Block) دسته‌بندی می‌شوند و درنهایت آخرین واحد به نام شبکه که خود دربرگیرنده تعداد زیادی بلوک می‌باشد. این ساختار در شکل (۱) مشخص است. در پردازش موازی باکمک پردازنده‌های

مرحله است: الف) کاهش پیش رو توسط معادلات (۱ و ۲)، ب) جایگزینی پس رو یعنی معادله (۳).

$$c'_1 = \frac{c_1}{b_1}, c'_i = \frac{c_i}{b_i - c'_{i-1}a_i} \quad (1)$$

$i = 2, 3, \dots, n-1$

$$d'_1 = \frac{d_1}{b_1}, d'_i = \frac{d_i - d'_{i-1}a_i}{b_i - c'_i a_i} \quad (2)$$

$i = 2, 3, \dots, n$

$$x_n = d'_n, x_i = d'_i - c'_i x_{i+1} \quad (3)$$

$i = n-1, n-2, \dots, 1$

الگوریتم کاهش متناوب. الگوریتم کاهش متناوب نیز مانند الگوریتم توماس یک الگوریتم دو مرحله‌ای است: (الف) کاهش پیش رو، (ب) جایگزینی پس رو [2]. در مرحله پیش رو، الگوریتم اندازه دستگاه را در هر مرحله به نصف کاهش می‌دهد و این روند را ادامه می‌دهد تا جایی که به دو معادله مستقل برسد. در هر مرحله مقادیر قطر اصلی و قطرهای بالا و پایین و سمت راست معادله طبق معادلات (۴-۶) تغییر می‌کنند. پس از آن که با استفاده از معادلات (۴-۶)، دستگاهی به اندازه ۲ در ۲ حاصل شد، این دستگاه دو معادله‌ای با روش‌های مرسوم حل می‌شود. در ادامه با استفاده از معادله (۷) می‌توان تمام مجھولات دیگر را به دست آورد. این مرحله جایگزینی پس رو نام دارد.

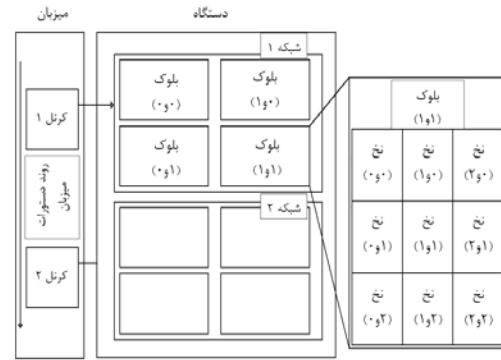
$$a'_i = -a_{i-1}k_1, b'_i = b_i - c_{i-1}k_1 - a_{i+1}k_2 \quad (4)$$

$$c'_i = -c_{i+1}k_2, d'_i = d_i - d_{i-1}k_1 - d_{i+1}k_2 \quad (5)$$

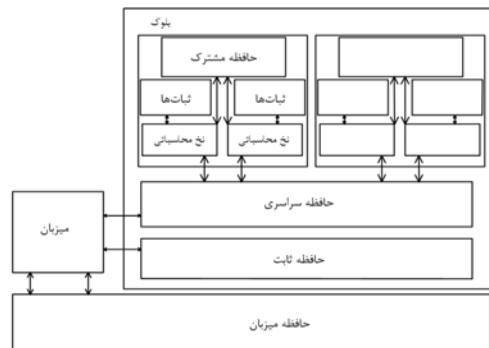
$$k_1 = \frac{a_i}{b_{i-1}}, k_2 = \frac{c_i}{b_{i+1}} \quad (6)$$

$$x_i = \frac{d'_i - a'_i x_{i-1} - c'_i x_{i+1}}{b'_i} \quad (7)$$

مقادیر معلوم است. در ماتریس ضرایب نیز سه قطر اصلی، قطر بالا و قطر پایین به ترتیب با a, b, c و a'_i, b'_i, c'_i نمایش داده شده‌اند. الگوریتم‌های متفاوتی برای حل چنین دستگاه معادلاتی وجود دارد اما به این دلیل که الگوریتم توماس یک الگوریتم بسیار سریع است برای به چالش کشیدن توانایی و سرعت پردازنده‌های گرافیکی در حل مسائل، انتخاب شده است. در این تحقیق الگوریتم توماس رایج و شناخته شده به نام الگوریتم توماس کلاسیک ذکر می‌شود تا از رهیافت توماس با رویکرد موازی که در ادامه معرفی می‌شود تمایز داده شود.



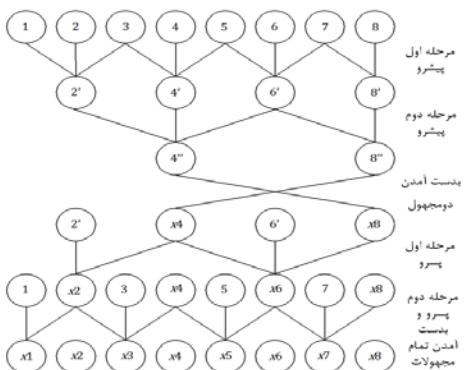
شکل ۱ ساختار پردازش موازی در روند اجرای برنامه



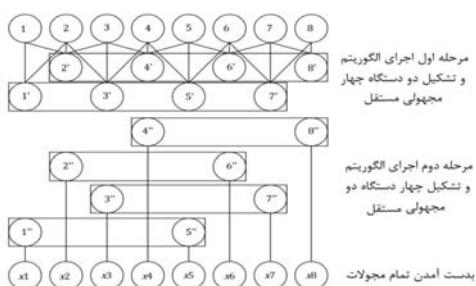
شکل ۲ ساختار حافظه در پردازنده گرافیکی

الگوریتم توماس کلاسیک. یکی از سریع ترین و پر کاربردترین الگوریتم‌های حل دستگاه معادلات الگوریتم توماس است. الگوریتم توماس شامل دو

رهیافت توماس موازی. رهیافت توماس موازی از این موضوع نشئت می‌گیرد که در مسائل با بیش از یک بعد، هر سطر از شبکه عددی (باتوجه به معادلات ۱۲ و ۱۳) می‌تواند یک دستگاه سه‌قطري تشکیل دهد که هر سطر یا هر دستگاه مستقل از دستگاه‌های دیگر می‌توانند حل شوند. در این روش وظیفه حل هر سطر یا هر دستگاه معادله سه‌قطري به یک نخ محاسباتی سپرده می‌شود. همان‌طور که در شکل (۵) مشخص است هر نخ محاسباتی می‌تواند یک دستگاه معادله را توسط الگوریتم توماس کلاسیک و مستقل از دستگاه‌های دیگر حل نماید. هر نخ محاسباتی بالاستفاده از معادلات (۱-۳) می‌تواند دستگاه مربوط به خود را حل نماید. مزیت این روش این است که از سرعت الگوریتم توماس بهره می‌برد و این بهره زمانی که چندین نخ به طور همزمان شروع به حل با این الگوریتم می‌کنند، چند برابر می‌شود.



شکل ۳ الگوریتم کاهش متناوب برای یک دستگاه ۸ معادله و ۸ مجھول

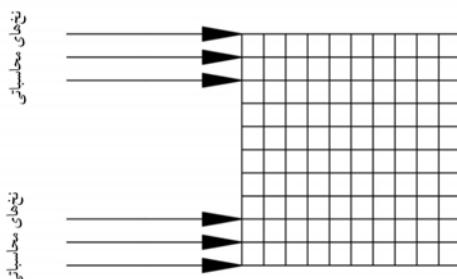


شکل ۴ مراحل الگوریتم کاهش متناوب موازی برای یک دستگاه ۸ مجھولی

شکل (۳) نشان دهنده الگوی الگوریتم کاهش متناوب برای یک دستگاه به اندازه ۸ در ۸ است. با سه بار اجرای الگوریتم روی دستگاه معادلات، با نصف شدن اندازه دستگاه در هر مرحله، در مرحله سوم دو معادله با دو مجھول به دست می‌آید که به سادگی قابل حل است.

الگوریتم کاهش متناوب موازی. الگوریتم کاهش متناوب موازی، یک الگوریتم بهبودیافته بر پایه الگوریتم کاهش متناوب است. اما برخلاف الگوریتم کاهش متناوب فقط دارای یک مرحله است و آن مرحله کاهش پیش رو است. تفاوت دیگر این دو الگوریتم این است که در الگوریتم کاهش متناوب موازی در هر مرحله ضرایب تمام معادلات تغییر می‌کنند. برای مثال در شکل (۴) مراحل الگوریتم کاهش متناوب موازی برای یک دستگاه ۸ معادله ۸ مجھول به صورت شماتیک نشان داده شده‌اند. در هر مرحله از الگوریتم کاهش متناوب موازی دستگاه معادلات به دو دستگاه کاملاً مستقل تبدیل می‌شوند. مرحله پیش رو در الگوریتم کاهش متناوب موازی بر پایه الگوریتم کاهش متناوب است و از معادلات (۴-۶) پیروی می‌کند. اما به جای مرحله پس رو که به دست آوردن مجھولات بالاستفاده از معادله (۷) است، الگوریتم کاهش متناوب موازی به تعداد مشخصی دستگاه دو معادله دو مجھول می‌رسد که به صورت موازی این دستگاه‌های مستقل قابل حل هستند. یکی از برتری‌های الگوریتم کاهش متناوب موازی بر الگوریتم کاهش متناوب در همین امر است که در هر لحظه تمام نخ‌های محاسباتی در حال انجام وظایف خود هستند، اما در الگوریتم کاهش متناوب در بیشتر مراحل، تعدادی از نخ‌های محاسباتی معطل می‌مانند و همین موضوع در عملکرد این الگوریتم تأثیر منفی دارد. بهترین حالت در پردازش موازی این است که در اجرای برنامه تمام نخ‌ها در گیر محاسبات باشند.

با استفاده از معادلات (۱۰) و (۱۱) می‌توان جریان لزج تراکم‌ناپذیر دو بعدی را در یک هندسه مستطیلی بدون نیاز به حل معادله پیوستگی تحلیل کرد. در این مسئله به سبب جریان بدون لغزش روی دیوارهای مؤلفه‌های سرعت روی دیوارهای ثابت صفر است. بنابراین با توجه به معادله (۸) می‌توان نتیجه گرفت که تابع جریان روی این دیوارهای یک عدد ثابت است (متلاً $\psi = 0$).



شکل ۵ ساختار نخ‌های محاسباتی برای اجرای رهیافت توماس موازی روی یک شبکه عددی

شرایط مرزی برای تاوایی روی مرزها نیز با استفاده از معادله (۱۱) به دست می‌آیند. برای حل معادلات، یک شبکه عددی همانند شکل (۶) در نظر گرفته می‌شود و معادلات (۱۰) و (۱۱) با روش تفاضل محدود تابع جریان- تاوایی اعمال شده است. معادلات تابع جریان- تاوایی بر مبنای تعریف تاوایی و تابع جریان به دست می‌آیند. تابع جریان توسط معادله (۸) و تاوایی نیز توسط معادله (۹) تعریف می‌شوند. همچنین معادله (۱۰) معادله جایه‌جایی- پخشی برای تاوایی است.

$$\begin{aligned} \psi_{i+1,j} + \psi_{i-1,j} - 2(1 + \beta^2)\psi_{i,j} &= \\ -\Delta x^2 \omega_{i,j} - \beta^2(\psi_{i,j+1} + \psi_{i,j-1}) & \end{aligned} \quad (۱۲)$$

$$\begin{aligned} \omega_{i+1,j} \left(1 + \frac{u_{i,j}\Delta x}{2v}\right) + \omega_{i-1,j} \left(1 - \frac{u_{i,j}\Delta x}{2v}\right) - 2(1 + \beta^2)\omega_{i,j} \\ = \beta^2(\omega_{i,j+1} + \omega_{i,j-1}) - \frac{\beta v_{i,j}\Delta x}{2v}(\omega_{i,j+1} - \omega_{i,j-1}) \end{aligned} \quad (۱۳)$$

هندسه مسئله و معادلات حاکم

برای به کار بردن الگوریتم‌های معرفی شده و بررسی عملکرد، دقت و سرعت این الگوریتم‌ها در مقایسه با الگوریتم توماس کلاسیک، مسئله جریان درون حفره در نظر گرفته شده است. شبیه‌سازی جریان درون حفره یکی از رایج‌ترین مسائل در دینامیک سیالات محاسباتی است، و تاکنون محققان بسیاری در مورد تمام جوانب این مسئله بحث و گفتگو کرده‌اند [۱۴-۱۱]. این مسئله به علت هندسه و شرایط مرزی ساده‌ای که دارد، عموماً در روش‌های جدید عددی از نتایج آن به عنوان یک نمونه اعتبارسنجی استفاده می‌کنند. در این مقاله، مسئله جریان درون حفره برای رینولدزهای ۱۰۰، ۴۰۰ و ۱۰۰۰ و در حالت پایدار بررسی و نتایج با مرجع [۱۱] مقایسه شده‌اند. برای شبیه‌سازی جریان درون حفره، روش تفاضل محدود روی معادلات تابع جریان- تاوایی اعمال شده است. معادلات تابع جریان- تاوایی بر مبنای تعریف تاوایی و تابع جریان به دست می‌آیند. تابع جریان توسط معادله (۸) و تاوایی نیز توسط معادله (۹) تعریف می‌شوند. همچنین معادله (۱۰) معادله جایه‌جایی- پخشی برای تاوایی است.

$$\mathbf{u} = \frac{\partial \psi}{\partial y}, \quad \mathbf{v} = -\frac{\partial \psi}{\partial x} \quad (۸)$$

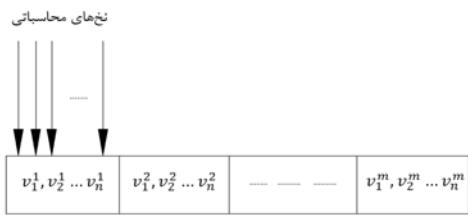
$$\boldsymbol{\omega} = \frac{\partial \mathbf{v}}{\partial x} - \frac{\partial \mathbf{u}}{\partial y} \quad (۹)$$

$$\mathbf{u} \frac{\partial \boldsymbol{\omega}}{\partial x} + \mathbf{v} \frac{\partial \boldsymbol{\omega}}{\partial y} = \mathbf{v} \left(\frac{\partial^2 \boldsymbol{\omega}}{\partial x^2} + \frac{\partial^2 \boldsymbol{\omega}}{\partial y^2} \right) \quad (۱۰)$$

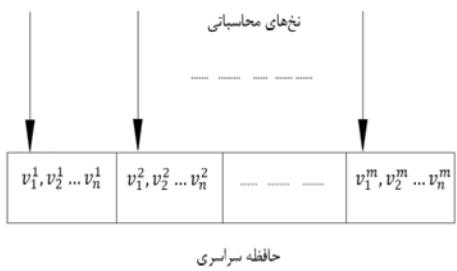
با قرار دادن معادله (۸) در معادله (۹)، رابطه‌ای بین تابع جریان و تاوایی به دست می‌آید:

$$\frac{\partial^2 \psi}{\partial x^2} + \frac{\partial^2 \psi}{\partial y^2} = -\boldsymbol{\omega} \quad (۱۱)$$

(۷ و ۸) به ترتیب دسترسی هم‌مکان و دسترسی غیر‌هم‌مکان (UnCoalesced Memory Access) به مقادیر یک متغیر دو بعدی ذخیره شده در حافظه سراسری توسط نخ‌های محاسباتی نشان داده شده‌اند. در شکل‌های (۷ و ۸) اندیس پایین‌نویس بیانگر شماره ستون و اندیس بالا‌نویس بیانگر شماره سطر است.



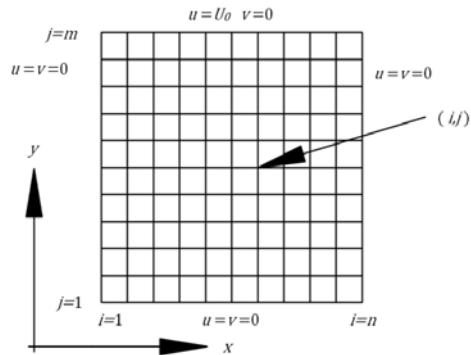
شکل ۷ دسترسی هم‌مکان نخ‌های محاسباتی به حافظه سراسری



شکل ۸ دسترسی غیر‌هم‌مکان نخ‌های محاسباتی به حافظه سراسری

بحث نتایج

در این قسمت ابتدا به بررسی صحیح بودن نتایج حل عددی و مقایسه با نتایج مرجع [11] پرداخته شده است. در این قسمت تمام نتایج برای تطابق با مرجع [11] بی‌بعد گزارش شده‌اند، که عبارتند از $V = \left(\frac{v}{U_0}\right)$, $X = \left(\frac{x}{L}\right)$, $Y = \left(\frac{y}{L}\right)$ و $\Omega = \left(\frac{\omega L}{U_0}\right)$. در شکل (۹) مؤلفه عمودی سرعت روی خط $Y = 0/5$ حاصل از حل مسئله توسط رهیافت توماس و دو الگوریتم کاهش متناوب و کاهش متناوب موازی گزارش و با مرجع [11] مقایسه شده است. به همین ترتیب مؤلفه افقی سرعت نیز روی خط $X = 0/5$ در شکل (۱۰) مورد مقایسه قرار گرفته‌اند. در شکل‌های



شکل ۶ شبکه عددی برای روش تفاضل محدود و شرایط مرزی سرعت

پیاده‌سازی الگوریتم روی پردازنده گرافیکی

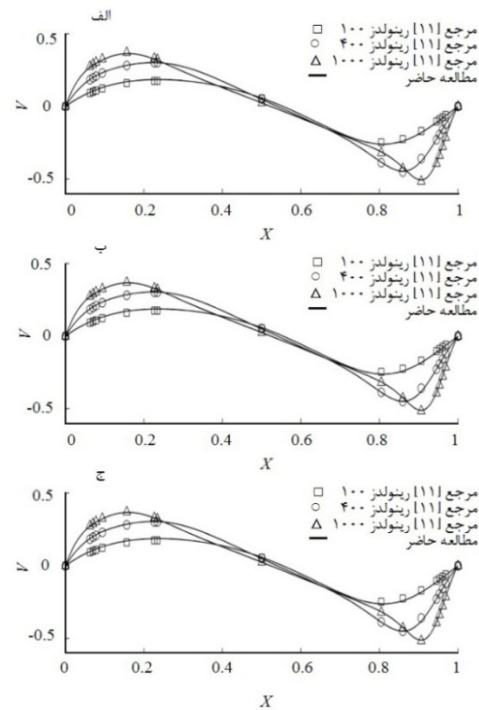
مسئله دیگری که در این تحقیق بررسی شده است، ارزیابی تأثیر به کار بردن مفهوم دسترسی هم‌مکان به حافظه در زمان حل است. در ساختار سخت‌افزار حافظه دستگاه و میزبان، متغیرها به صورت خطی ذخیره می‌شوند. به عنوان مثال اگر یک ماتریس در حافظه ذخیره شده باشد، درایه اول از سطر اول ماتریس در مکان مشخصی از حافظه ذخیره می‌شود و به ترتیب درایه‌های بعدی در ادامه ذخیره می‌شوند تا آخرین درایه سطر اول، بعد از آن اولین درایه سطر دوم آدرس دهی و ذخیره‌سازی می‌شود و به همین ترتیب این روند تکرار می‌شود. برای میزبان به علت این‌که ساختار ترتیبی دارد در هر لحظه پردازنده فقط به یک قسمت حافظه نیاز دارد اما در مورد پردازنده گرافیکی به علت این‌که چندین پردازنده هم‌زمان در حال پردازش هستند و طبیعتاً هر پردازنده بنا بر دستوری که اجرا می‌کند ممکن است به مقادیر ذخیره شده در قسمت‌های مختلف حافظه نیاز داشته باشد و در واقع فرآخوانی هم‌زمان مقادیر از قسمت‌های مختلف حافظه با توجه به پهنهای باند حافظه، می‌تواند سرعت پردازنده گرافیکی را تا حد چشم‌گیری کاهش دهد. برای حل این مشکل در پردازش موازی باید دقیق شود که نخ‌های محاسباتی هنگام پردازش به یک منطقه از حافظه نیاز داشته باشند که با یکبار فرآخوانی از حافظه نیاز تمام نخ‌ها برآورده شود. در شکل‌های

نتیجه‌گیری

در این تحقیق دو الگوریتم کاهش متناوب و کاهش متناوب موازی برای اجرا روی پردازنده‌های گرافیکی معرفی شدند و هم‌چنین برپایه الگوریتم توماس کلاسیک، این ایده مطرح شد که می‌توان دستگاه معادلات مربوط به هر سطر محاسباتی را مستقل از دیگر دستگاه‌ها حل کرد و این نکته منجر به استفاده رهیافت توماس موازی شد. با پیاده‌سازی این الگوریتم‌ها روی پردازنده گرافیکی، اجرا و حل مسئله جریان درون حفره، نتایج حاصل از حل توسط پردازنده گرافیکی با نتایج حل روی پردازنده مرکزی و مرجع [11] از تطابق قابل قبولی برخوردار بودند. افزایش سرعت زمان حل برای اندازه‌های مختلف شبکه از 64×64 تا 1024×1024 نسبت به زمان حل پردازنده مرکزی، برای الگوریتم کاهش متناوب بین $0/4$ تا $4/4$ به دست آمد و برای الگوریتم کاهش متناوب موازی از $0/2$ تا $5/2$ متغیر بود. اما رهیافت توماس موازی نیز با دو نوع رویکرد متفاوت از نوع دسترسی به حافظه سراسری مورد بررسی قرار گرفت. در زمانی که دسترسی از نوع هم‌مکان صورت گرفت حداقل $38/5$ و در دسترسی غیر‌هم‌مکان تا $20/3$ برابر، افزایش سرعت حاصل می‌شد. در دسترسی هم‌مکان در تمام اندازه‌های شبکه محاسباتی رهیافت توماس موازی در حل مسئله افزایش سرعت نشان داد اما هنگامی که نوع دسترسی به حافظه بهینه نبود، سرعت حل بالا نبود و حتی در اندازه شبکه 64×64 کاهش سرعت نسبت به زمان حل پردازنده مرکزی ثبت شد. روش اجرای رهیافت توماس موازی به‌گونه‌ای است که برای دیگر روش‌های حل نیز کاربرد خواهد داشت. زمانی که بتوان هر سطر محاسباتی را مستقل از دیگر سطراها حل نمود، محاسبات هر سطر را یک نخ محاسباتی می‌تواند به عهده گیرد خواه دستگاه معادله تشکیل شده سه‌قطري باشد، خواه پنج‌قطري؛ یعنی می‌توان معادلات را با

(۱۰) و (۱۱) مقادیر برای نتایج حل با یک شبکه 128×128 ارائه شده‌اند.

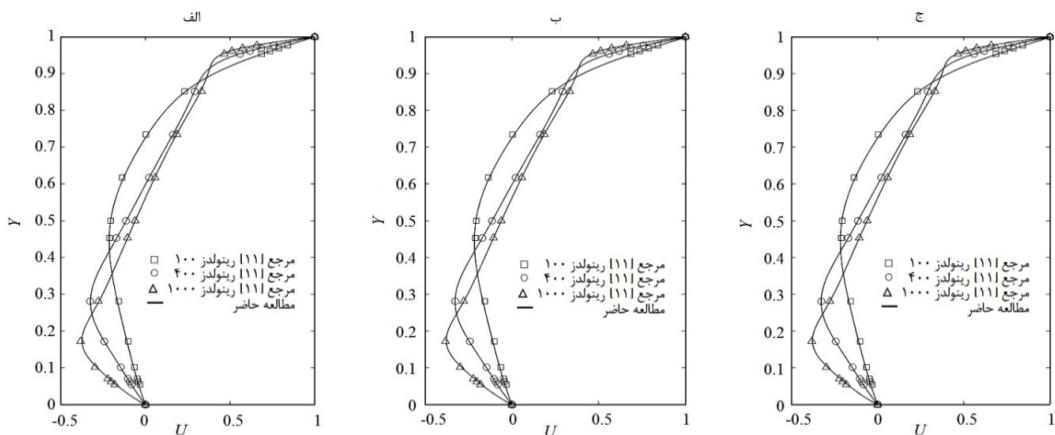
در شکل (۱۱) افزایش سرعت زمان حل مسئله جریان درون حفره توسط اجرای رهیافت توماس، الگوریتم کاهش متناوب و کاهش متناوب موازی روی پردازنده گرافیکی با زمان حل مسئله توسط پردازنده مرکزی و اجرای الگوریتم توماس کلاسیک برای ۱۰۰۰ تکرار در رینولذ ۱۰۰۰ مقایسه شده‌اند. در شکل (۱۲) افزایش سرعت رهیافت توماس موازی اجراشده روی پردازنده گرافیکی، با دسترسی‌های هم‌مکان و غیر‌هم‌مکان نسبت به الگوریتم توماس کلاسیک اجراشده روی پردازنده مرکزی، مقایسه شده‌اند. مشخص است که در هر تعداد گره محاسباتی سرعت الگوریتم با دسترسی هم‌مکان حدوداً دو برابر سرعت الگوریتم با دسترسی غیر‌هم‌مکان است.



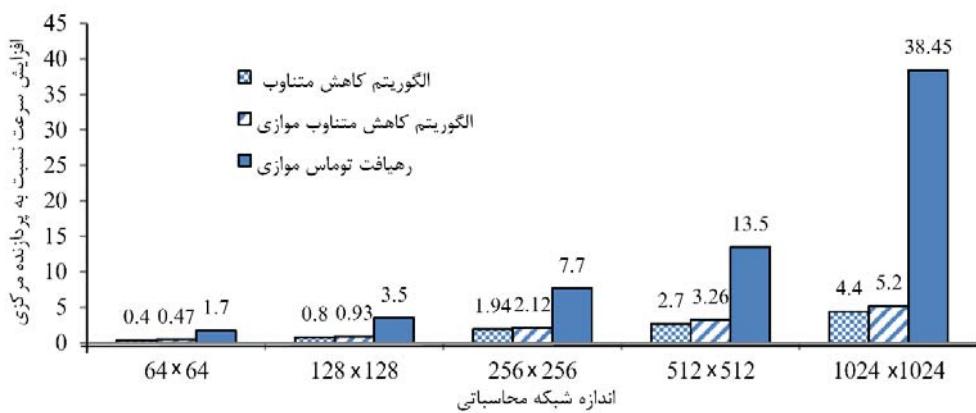
شکل ۹ نمایش مؤلفه عمودی سرعت روی خط $X = 0/5$ برای سه عدد رینولذ ۱۰۰، ۴۰۰ و ۱۰۰۰ حاصل از نتایج: (الف) رهیافت توماس موازی، (ب) الگوریتم کاهش متناوب، (ج) الگوریتم کاهش متناوب موازی

موازی بهره گرفت. از دیگر مزیت‌های رهیافت توماس موازی، محدود نبود اندازه دستگاه معادلات به 2^n ذکر شد. این توانایی می‌تواند گستره کاربرد این رهیافت را افزایش دهد. درنهایت از نتایج ارائه شده می‌توان دریافت که استفاده از پردازنده‌های گرافیکی به عنوان شتاب‌دهنده به محاسبات عددی، یک ابزار کارآمد و بسیار سریع و مقرون‌به‌صرفه به حساب می‌آیند و می‌توان در آینده برای تحقیقات گوناگون از قدرت آنها سود برد.

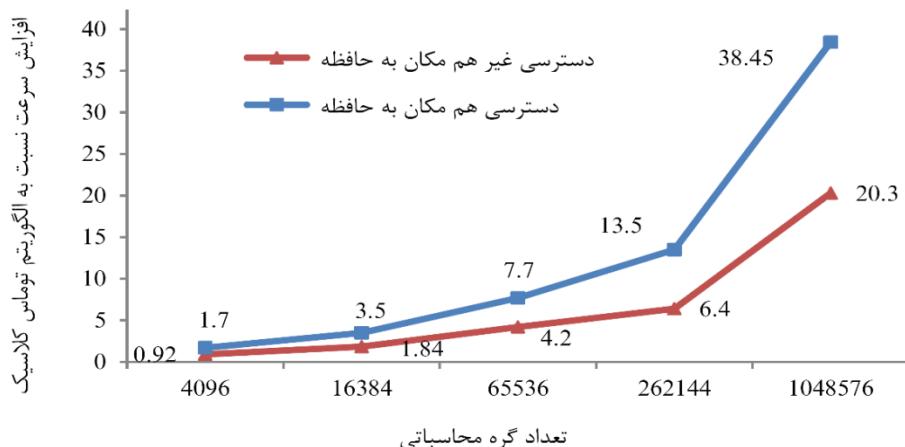
مرتبه بالاتر گستته کرد (افزایش درگیری تعداد گره‌های محاسباتی) که طبیعتاً ماتریس ضرایب از حالت سه‌قطري خارج می‌شود و برای مثال به یک ماتریس پنج‌قطري تبدیل می‌گردد. در این شرایط می‌توان از روش‌هایی نظری به کار بردن الگوریتم توماس بلوکی برای هر سطر یا مطابق مراجع [15, 16] اعمال روش ضمنی برای متغیر فشرده (ADI Compact) به منظور تبدیل معادلات گستته مرتبه بالاتر به یک دستگاه سه‌قطري، استفاده نمود و سپس برای حل آنها از الگوریتم‌های معرفی شده و ترجیحاً رهیافت توماس



شکل ۱۰ نمایش مؤلفه افقی سرعت روی خط $X = 0/5$ برای سه عدد رینولدز 100 ، 400 و 1000 حاصل از نتایج: (الف) رهیافت توماس موازی، (ب) الگوریتم کاهش متنابوب، (ج) الگوریتم کاهش متناوب موazی



شکل ۱۱ نمایش افزایش سرعت زمان حل الگوریتم‌های موازی برای رینولدز 1000 در طی 1000 تکرار



شکل ۱۲ مقایسه افزایش سرعت پردازش موازی در بازه مرکزی در حالت دسترسی هم مکان و غیر هم مکان به حافظه برای تعداد گره محاسباتی مختلف در رینولدز ۱۰۰۰

فهرست علائم	
a	قطر پایین در ماتریس سه‌قطري
A	ماتریس ضرایب
b	قطر اصلی در ماتریس سه‌قطري
c	قطر بالا در ماتریس سه‌قطري
d	بردار مقادیر معلوم
i	شمارنده گره محاسباتی در راستای محور طول
j	شمارنده گره محاسباتی در راستای محور عرض
L	مقدار طول و عرض حفره (m)
m	تعداد سطراها
n	تعداد ستونها
U_0	سرعت روی مرز متحرک (ms-1)
u	مؤلفه افقی سرعت (ms-1)
U	مؤلفه افقی سرعت (بدون بعد)

علایم یونانی

V	مؤلفه عمودی سرعت (ms-1)
V	مؤلفه عمودی سرعت (بدون بعد)
x	محور طول (m)
X	محور طول بدون بعد
y	محور عرض (m)
Y	محور عرض بدون بعد
ψ	تابع جریان ($m^2 s^{-1}$)
ω	تاوایی (s^{-1})
Ω	تاوایی (بدون بعد)
U	لرجت سینماتیکی ($m^2 s^{-1}$)

مراجع

- Accessed 30 November, 2014; <http://www.top500.org/>.
- Zhang, Y. Owns, J.D. and Cohen, J., "Fast Tri-diagonal Solvers on the GPU", *Proceeding of the 15th ACM SIGPLAN Symposium on Principles and Practice of Parallel Programming*, Bangalore, January 09-14, (2010).

3. Göddeke, D. and Strzodka, R., "Cyclic Reduction Tri-diagonal Solvers on GPUs Applied to Mixed-Precision Multigrid", *IEEE Transactions on Parallel and Distributed Systems*, Vol. 22, No. 1, (2011).
4. Davidson, A., Zhang, Y. and Owens, J.D., "An Auto-tuned Method for Solving Large Tri-diagonal Systems on the GPU", in *Proceedings of the 25th IEEE International Parallel and Distributed Processing Symposium*, Anchorage, Alaska, (2011).
5. Egloff, D., "High performance finite difference PDE solvers on GPUs", Quant Alea GmbH, Technical report, February (2010).
6. Kim, H.S., Chang, L.W., Wu, S. and Hwu, W.W., "A Scalable Tri-diagonal Solver for GPUs", *International Conference on parallel processing*, Taipei, pp. 444-453, 13-16 Sept. (2011).
7. Tutkun, B. and Edis, F.O., "A GPU application for high-order compact finite difference scheme", *Computers & Fluids*, Vol. 55, No. 11, pp. 29-35, (2012).
8. Esfahanian, V., Darian, H.M. and Gohari, S.M.I. "Assessment of WENO schemes for numerical simulation of some hyperbolic equations using GPU", *Computers & Fluids*, Vol. 80, pp. 260-268, (2012).
9. Esfahanian, V., Baghapour, B., Torabzadeh, M. and Chizari, H., "An efficient GPU implementation of cyclic reduction solver for high-order compressible viscous flow simulations", *Computers & Fluids*, Vol. 92, pp. 160-171, (2014).
10. Darian, H.M. and Esfahanian, V. "Assessment of WENO schemes for multi-dimensional Euler equations using GPU", *Numerical Methods in Fluids*, Vol. 76, pp. 961-981, (2014).
11. Ghia, U., Ghia, K.N. and Shin, C.T., "High-Re solutions for incompressible flow using the Navier Stokes equations and a multigrid method", *Journal of Computational Physics*, Vol. 48, No. 3, pp. 387-411, (1982).
12. Bicudo, P. and Cardoso, N., "Time dependent simulation of the Driven Lid Cavity at High Reynolds Number", *Physics of Fluid Dynamics*, Vol. 1, pp. 1-20 (2009).
13. Erturk, E., "Discussions on Driven Cavity Flow", *Numerical Methods in Fluids*, Vol. 60, pp. 275-294, 2009.
14. Poochinapan, K., "Numerical Implementations for 2D Lid-Driven Cavity Flow in Stream Function Formulation", *ISRN Applied Mathematics*, Vol. 2012, Article ID 871538, pp. 1-17, (2012).
15. Tiana, Z.F. and Geb, Y.B., "A Fourth-Order Compact ADI Method for Solving Two-Dimensional Unsteady Convection-Diffusion Problems", *Journal of Computational and Applied Mathematics*, Vol. 198, No. 1, pp. 268 – 286, (2007).
16. Erturk, E., "Numerical Performance of Compact Fourth Order Formulation of the Navier-Stokes equations", *Communications in Numerical Methods in Engineering*, Vol. 24, pp. 2003-2019, (2008).