

*Advances in computational fluid dynamics. Supercomputing, artificial intelligence and new paradigms and their application in Ansys Fluent software*

## Postęp w obliczeniowej mechanice płynów. Superkomputery, sztuczna inteligencja i nowe paradygmaty oraz ich zastosowanie w oprogramowaniu Ansys Fluent



DOI: 10.15199/62.2026.5.5

*A review, with 25 refs., of current trends in computational fluid dynamics (CFD). The results of own simulations and various literature data were presented. The speed up of calcns. achieved by using graphics cards was evidenced. Use of supercomputers, advances in quantum computers and the application of artificial intelligence were briefly discussed. Several examples of new paradigms in CFD (meshless simulations, new meshing methods and browser-based modelling) were also given.*

**Keywords:** CFD, GPU calculation, AI, HPC

Przegląd współczesnych trendów w obliczeniowej mechanice płynów. Zaprezentowano wyniki własnych symulacji oraz różnorodne przykłady z literatury. Pokazano przyspieszenie obliczeń, które można osiągnąć dzięki wykorzystaniu kart graficznych. Wymienione i pokrótce omówione zostały takie technologie, jak wykorzystanie superkomputerów do obliczeń, postępy w komputerach kwantowych i zastosowanie sztucznej inteligencji. Podano też kilka przykładów nowych paradygmatów obliczeniowej mechaniki płynów (symulacje bezsiatkowe, nowe metody siatkowania, modelowanie z poziomu przeglądarki).

**Słowa kluczowe:** obliczeniowa mechanika płynów, procesory graficzne, sztuczna inteligencja, HPC

Choć początki obliczeniowej mechaniki płynów datuje się na pierwszą połowę XX w., to właśnie współcześnie dziedzina ta przeżywa rozkwit dzięki znacznym postępom w numeryce, sprzęcie komputerowym i algorytmach. Implementowane są najnowsze zdobycze technologii, takie jak sztuczna inteligencja, do przyspieszenia obliczeń wykorzystuje się potężne centra komputerowe, a obliczenia wykonuje się na kartach graficznych GPU (*graphics processing unit*), wielokrotnie

szybszych od procesorów CPU (*central processing unit*). Ten postęp pozwala na zmianę podejścia, w którym konieczne niegdyś uproszczenia mogą być wycofywane i można analizować przebieg nieosiągalnych wcześniej procesów oraz bardziej złożonych i skomplikowanych układów. Dlatego warto aktualizować wiedzę, aby przeprowadzać symulacje w optymalny sposób, ograniczając czas i koszt obliczeń, co jest szczególnie ważne zwłaszcza w zastosowaniach komercyjnych.



Mgr inż. Piotr CENDROWSKI (ORCID: 0000-0002-5089-8811) w roku 2018 ukończył studia na Politechnice Warszawskiej, kierunek inżynieria chemiczna i procesowa. Obecnie pracuje nad uzyskaniem stopnia doktora. Od 2024 r. jest zatrudniony na stanowisku starszego specjalisty Pionu Badawczego w Dziale Modelowania Procesów Chemicznych w Sieci Badawcza Łukasiewicz – Instytucie Chemii Przemysłowej imienia Profesora Ignacego Mościckiego w Warszawie, gdzie zajmuje się opracowywaniem koncepcji instalacji przemysłowych i prowadzeniem modelowania procesów za pomocą oprogramowania do obliczeniowej mechaniki płynów (Ansys Fluent). Brał udział w dużych projektach realizowanych dla znaczących firm z polskiego przemysłu chemicznego, np. Anwil SA czy Grupa Azoty. Specjalność – obliczeniowa mechanika płynów, modelowanie matematyczne oraz zastosowania płynów w stanie nadkrytycznym.



Dr inż. Zbigniew LASKOWSKI (ORCID: 0000-0002-9778-6008) ukończył studia na Wydziale Inżynierii Chemicznej i Procesowej Politechniki Warszawskiej. Stopień doktora nauk chemicznych uzyskał w 1994 r. na tej samej uczelni. Od 2018 r. jest zatrudniony w Sieci Badawcza Łukasiewicz – Instytucie Chemii Przemysłowej imienia Profesora Ignacego Mościckiego w Warszawie, obecnie na stanowisku lidera obszaru badawczego. Wcześniej przez 14 lat był kierownikiem Wydziału Badań i Rozwoju w Mennica Metale Szlachetne SA. W ostatnich latach w Ł-ICHp zajmował się analizą techniczno-ekonomiczną różnych procesów przemysłu chemicznego, doradztwem technicznym, współpracował w tematach związanych z gospodarką wodorową. Jest współautorem 17 zgłoszeń patentowych oraz wystąpień na konferencjach. Specjalność – metalurgia pierwiastków rzadkich i ich stopów, metalurgia proszków, analiza procesów technologicznych, a w szczególności procesów związanych z produkcją kwasu azotowego.

**\* Adres do korespondencji:**

Sieć Badawcza Łukasiewicz – Instytut Chemii Przemysłowej imienia Profesora Ignacego Mościckiego, ul. Rydygiera 8, 01-793 Warszawa, e-mail: piotr.cendrowski@ichp.lukasiewicz.gov.pl

## Wykorzystanie GPU oraz klastrów obliczeniowych/superkomputerów do obliczeniowej mechaniki płynów HPC (*high-performance computing*)

Wiele firm i naukowców na całym świecie wytrwale rozwija technologie komputerowe. Jednym aspektem są rozwiązania ze sfery oprogramowania (*software*). W tym rozdziale nacisk zostanie jednak położony na drugi, blisko związany aspekt sprzętowy (*hardware*). Już w 1965 r. Gordon Moore, prezes firmy Intel, zauważył pewną prawidłowość w tempie rozwoju możliwości sprzętowych komputerów. Od jego nazwiska nazywa się ją prawem Moore'a. W skrócie mówi ona, że liczba tranzystorów w układzie scalonym podwaja się co ok. 2 lata (rys. 1)<sup>1,2</sup>. Później prawo to rozszerzono na inne wielkości dotyczące komputerów, takie jak moc obliczeniowa oraz rozmiar pamięci RAM (*random-access memory*) i dysków twardek. Współcześnie okazuje się jednak, że rozwój taki nie może zostać utrzymany. Problemami są prawa fizyki (nie można w nieskończoność ani miniaturyzować układów, ani przekroczyć szybkości światła), rosnące zużycie prądu (a w konsekwencji wzrost generowania ciepła w układach elektronicznych) oraz ograniczenia architektury (np. konieczność odczytywania danych z wolniejszych elementów, takich jak pamięć RAM)<sup>3</sup>. W związku z tym obecnie potencjału na przyspieszenie upatruje się w zrównoległaniu wykonywania obliczeń oraz w układach wieloprocesorowych.

W trendy te wpisuje się również sektor symulacji numerycznych. Intensywnie rozwija się oprogramowanie, które pozwala wykorzystywać wiele rdzeni, wiele procesorów CPU, a ostatnio także dedykowane karty graficzne GPU. W kolejnym

rozdziale opisane zostały obliczenia autorów, które pokazują jak znaczne przyspieszenie obliczeń można uzyskać dzięki wykorzystaniu procesorów graficznych. Znane są także inne zastosowania nowoczesnych technik komputerowych: symulacje wykonywane z wykorzystaniem komputera kwantowego oraz obliczenia w wielkiej skali wykonywane na specjalistycznych superkomputerach. Przykładem takiego obliczenia dużej skali na superkomputerach jest modelowanie przewodzone przez inżynierów z firmy Ansys. Przygotowali oni model samolotu naddźwiękowego<sup>4</sup>. Do przeprowadzenia symulacji stworzono wysoce złożoną siatkę składającą się z 172 mln elementów, precyzyjnie odwzorowującą powierzchnię odrzutowca. Taka liczba komórek jest absolutnie nieosiągalna ani podczas pracy na zwykłym komputerze, ani na małym klastrze obliczeniowym. Zastosowany superkomputer stworzył tę siatkę numeryczną w zaledwie 11 min, wykorzystując 192 procesory CPU. Symulację przeprowadzono z wykorzystaniem kart GPU, obliczenia te zajęły niecałe 4 h (zasymulowano 5 s czasu rzeczywistego lotu samolotu). Dla porównania, obliczenia tej skali na procesorach CPU zajęłyby tygodnie. Potencjał tak znacznego skrócenia czasu modelowania otwiera inżynierom wiele możliwości. Procesy, które do tej pory pozostawały poza zasięgiem (ze względu na ograniczenia czasowe i sprzętowe) teraz stają się dostępne.

## Wykorzystanie procesorów graficznych do skrócenia czasu obliczeń w programie Ansys Fluent

Symulacje CFD (*computational fluid dynamics*) polegają na numerycznym rozwiązywaniu równań opisujących




Fig. 1. Moore's law (depicted as increase of computational power in time) from 1900 to 2024<sup>3</sup>

Rys. 1. Prawo Moore'a (czyli wzrost mocy obliczeniowej w czasie) w latach 1900–2024<sup>3</sup>

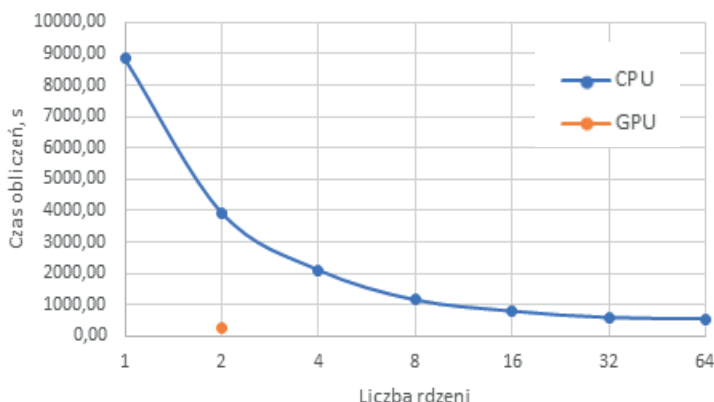


Fig. 2. Effect of the number of processing units on computation time

Rys. 2. Wpływ liczby jednostek obliczeniowych na czas obliczeń

przepływ płynów: równania Naviera i Stokesa oraz równania ciągłości. Obliczenia te wymagają dużej mocy obliczeniowej, ponieważ obejmują podział analizowanej przestrzeni na siatkę dyskretną (*mesh*), a następnie iteracyjne wyznaczanie wartości parametrów fizycznych w każdym punkcie tej siatki. Wykorzystanie jednostek CPU i GPU w tego typu symulacjach różni się zarówno architekturą sprzętową, jak i sposobem równoległego przetwarzania danych.

CPU to uniwersalna jednostka obliczeniowa, wyposażona w niewielką liczbę rdzeni (zwykle od kilku do kilkudziesięciu), które są zoptymalizowane pod kątem zadań sekwencyjnych i ogólnego przetwarzania danych. Rdzeń procesora to podstawowa jednostka wykonawcza, która potrafi niezależnie wykonywać ciąg instrukcji, a tym samym odpowiada za realizację obliczeń. Rdzenie CPU cechują się wysoką częstotliwością taktowania, czyli wyrażaną w GHz liczbą cykli zegara wykonywanych w ciągu 1 s. Taktowanie określa, jak szybko rdzeń procesora jest w stanie wykonywać operacje, przy czym wyższa częstotliwość oznacza potencjalnie większą wydajność pojedynczego rdzenia. CPU dobrze sprawdza się w zadaniach wymagających złożonych obliczeń i operacji logicznych, ale równoległość obliczeń jest ograniczona liczbą rdzeni. W praktyce zwiększanie liczby rdzeni CPU pozwala na proporcjonalne przyspieszenie obliczeń, jednak skalowalność jest ograniczona narzutami związanymi z komunikacją międzyprocesową i synchronizacją danych.

GPU to jednostka obliczeniowa zaprojektowana pierwotnie do przetwarzania grafiki, obecnie szeroko wykorzystywana w obliczeniach naukowych. GPU składa się z tysięcy prostszych rdzeni, które pracują równolegle w modelu masowego przetwarzania danych. Rdzenie GPU są mniej złożone niż rdzenie CPU, ale ich ogromna liczba umożliwia wykonywanie wielu operacji jednocześnie. W kontekście symulacji numerycznych GPU umożliwia jednoczesne wykonywanie obliczeń w wielu punktach siatki numerycznej, co pozwala znacząco skrócić czas symulacji w porównaniu z CPU. Efektywność GPU wynika z dużej przepustowości pamięci, czyli zdolności do szybkiego przesyłania danych między pamięcią a rdzeniami oraz wysokiego stopnia równoległości. Ograniczeniem GPU jest mniejsza elastyczność w obsłudze

skomplikowanych operacji warunkowych i większa zależność od optymalizacji kodu.

Podstawowa różnica między obliczeniami na CPU i GPU polega więc na sposobie wykorzystania równoległości. CPU oferuje mniejszą liczbę rdzeni, ale bardziej uniwersalnych i wszechstronnych, natomiast GPU udostępnia bardzo dużą liczbę rdzeni o uproszczonej strukturze, przystosowanych do masowych obliczeń równoległych. W symulacjach zwiększanie liczby rdzeni CPU pozwala na stopniowe przyspieszenie obliczeń, natomiast zastosowanie GPU umożliwia radykalne skrócenie czasu obliczeń dzięki skalowaniu równoległemu, szczególnie w przypadku dużych siatek numerycznych i zadań wymagających powtarzalnych obliczeń dla wielu węzłów siatki. Wybór pomiędzy CPU a GPU zależy więc od charakteru problemu, struktury kodu oraz dostępnych zasobów obliczeniowych, przy czym GPU jest zazwyczaj wydajniejszym rozwiązaniem dla dużych i intensywnie równoległych symulacji CFD. Występują jednak pewne ograniczenia w stosowaniu jednostek GPU do przyspieszenia obliczeń. Jak wspomniano wcześniej, ten typ obliczeń wymaga specjalnie dostosowanego kodu. Pomimo kolejnych wersji i aktualizacji, nie wszystkie modele udało się dostosować do tej technologii<sup>5)</sup>. Dlatego przed rozpoczęciem pracy konieczna jest weryfikacja, czy proces, który ma być symulowany może zostać opisany z wykorzystaniem dostępnych modeli. Drugim aspektem jest wielkość siatki obliczeniowej. Karty graficzne posiadają mniej pamięci do przechowywania danych niż procesory VRAM (*video random access memory*) dla kart graficznych i RAM dla procesorów. To z kolei przekłada się na konieczność ograniczania wielkości siatek, tak aby zmieściły się one na dostępnej przestrzeni. Ze względu na znakomite możliwości obliczeniowe, również naukowcy zainteresowali się zastosowaniem GPU w pracach symulacyjnych. Przykładowo Gou i Shen<sup>6)</sup> zaproponowali model łączący podejście obliczeniowej mechaniki płynów z metodą elementów dyskretnych (DEM) do przepływu wielofazowego ciała stałe-gaz. Jednym z wyzwań w symulacjach dla takich układów jest ich rozmiar: wiele cząstek ciała stałego, duże domeny obliczeniowe (np. wielkości instalacji przemysłowej) oraz często wiele równań modelowych (np. w przypadku reakcji chemicznej). Autorzy zastosowali ciekawy zabieg celem optymalizacji wykorzystania zasobów obliczeniowych. Równania odpowiedzialne za przepływ płynu były wykonywane za pomocą CPU, a przepływ cząstek ciała stałego oraz sprzęganie wyników obydwu modeli za pomocą GPU. Dla nowego hybrydowego algorytmu odnotowano znaczne skrócenie czasu obliczeń, a także zweryfikowano go dla przypadku symulacji procesu przemysłowego, otrzymując dobrą zgodność z wynikami doświadczalnymi. Podobnymi symulacjami zajmował się też Yu i współpr.<sup>7)</sup>. Zespół przygotował własny kod w języku Fortran, który rozwiązywał równania przepływu w układzie gaz-ciało stałe. Analogicznie jak w pracy<sup>6)</sup> za przepływ płynu odpowiadał kod przygotowany na CPU, a za przepływ cząstek ciała stałego program napisany na GPU. Przygotowany model pozwalał też na obliczenia pełnego, trójwymiarowego aparatu

do fluidyzacji, co wcześniej było ogromnym wyzwaniem dla obliczeniowej mechaniki płynów, ze względu na złożoność obliczeniową i rozmiar domeny obliczeniowej.

To, jak można znacznie przyspieszyć obliczenia dzięki wykorzystaniu procesorów graficznych, przedstawia przykład badań własnych autorów pracy.

Celem przeprowadzonej symulacji było zbadanie wpływu zastosowanych jednostek obliczeniowych oraz liczby wykorzystywanych rdzeni na czas obliczeń oraz przebieg residuów. Przeprowadzono 7 symulacji, wykorzystując obliczenia CPU dla wzrastającej liczby rdzeni od 1 do 64 oraz obliczenia wykorzystujące karty graficzne GPU. Przedmiotem symulacji był trójkąt w kształcie litery „T” z 2 wlotami oraz jednym wylotem. W układzie uwzględniono proces wymiany ciepła. Doprowadzane strumienie miały temp. 20°C oraz 81°C. Przepływ miał charakter turbulentny, liczby Reynoldsa przekraczały wartość 20 000.

Na rys. 2 przedstawiono wyniki przeprowadzonych obliczeń. Sprawdzano, o ile szybciej można przeprowadzić obliczenia, zmieniając 2 parametry: liczbę wykorzystywanych procesorów w CPU (niebieskie punkty na wykresie), oraz czy do obliczeń wykorzystywano procesor graficzny GPU (pomarańczowy punkt na wykresie). Do obliczeń z wykorzystaniem procesorów graficznych stosowano 2 rdzenie CPU i 2 jednostki GPU. Wynikało to z faktu, że program Ansys Fluent narzuca wykorzystanie takiej samej liczby procesorów CPU co GPU. Serwer obliczeniowy wykorzystywany w pracy miał procesor CPU AMD Ryzen Threadripper PRO 5995WX z 64 rdzeniami o taktowaniu 2,7 GHz oraz 2 karty graficzne NVIDIA RTX A2000 z 6 GB pamięci VRAM. Każda z tych kart graficznych posiada własne rdzenie, które wykorzystuje do obliczeń w różnym stopniu, w zależności od wykonywanych zadań.

Bazowy czas obliczeń dla jednego rdzenia CPU wynosił ok. 9000 s. Dla ułatwienia opracowania wyników wartości zebrano w tabeli.

W tabeli podano wyniki obliczeń współczynnika przyspieszenia. Jest to stosunek wartości bazowej (czasu obliczeń dla 1 rdzenia CPU) do czasu obliczeń dla danego wariantu. Do momentu zwiększenia liczby rdzeni do 8 obserwuje się wzrost liniowy, który następnie spowalnia. Może to być spowodowane rosnącymi trudnościami z wymianą informacji między procesorami, co zmusza je do czekania z obliczeniami aż do czasu pełnej synchronizacji. Jest to znane zjawisko związane z prawem Amdahla<sup>8)</sup>. Największe przyspieszenie obliczeń zaobserwowano dla wariantu z wykorzystaniem jednostek GPU. Jest to aż 32-krotne skrócenie czasu obliczeń względem wariantu bazowego (lub 16-krotne, jeżeli odnieść je do wariantu z tą samą liczbą rdzeni CPU). Wynik ten zdecydowanie uzasadnia korzystanie z pomocy procesorów graficznych w obliczeniowej mechanice płynów, o ile spełnione zostaną warunki, o których wspomniano we wstępie. Warto jednak odnotować, że trudno jest bezpośrednio porównywać liczbę rdzeni w zestawieniu CPU/GPU. Specjalistyczne, obliczeniowe karty graficzne mają nawet kilka tysięcy małych, wyspecjalizowanych rdzeni, gru-

Table. Calculation time and speed up depending on the number of computing cores used

Tabela. Czas obliczeń i przyspieszenie obliczeń w zależności od liczby wykorzystywanych rdzeni obliczeniowych

Liczba rdzeni	Czas obliczeń, s	Współczynnik przyspieszenia
1	8843	1
2	3930	2
4	2098	4
8	1145	8
16	783	11
32	576	15
64	539	16
2 GPU	275	32

powanych w większe zbiory. Przykładowo karta wykorzystana w tej pracy ma 3328 rdzeni CUDA, które pogrupowane są w 26 większych jednostek zwanych *streaming multiprocessor* (SM). Jak wspomniano we wstępie, GPU i CPU realizują różne zadania i lepiej sprawdzają się w różnych typach zastosowań. Dlatego warto jest korzystać z pomocy GPU w celu skrócenia czasu obliczeń. Innym aspektem jest też zużycie energii. Dedykowane centra komputerowe wyposażane są w specjalistyczne systemy chłodzenia z powodu wysokiej temperatury osiąganego przez superkomputery podczas pracy przy dużym obciążeniu. Ciepło wydzielane przez dany podzespół komputerowy jest określane za pomocą parametru TDP (*thermal design power*). Należy go rozumieć jako ilość energii cieplnej, którą wydziela dany element komputera podczas pracy przy bazowej częstotliwości i przy obciążeniu wszystkich rdzeni. W wykorzystanej stacji roboczej dla CPU wartość ta wynosiła 280 W, a dla GPU 70 W. Oznacza to, że 2 procesory graficzne wydzielają 2 razy mniej ciepła niż w pełni obciążony CPU, jednocześnie 2-krotnie skracając czas obliczeń. To pozwala wnioskować, że zastosowanie GPU ma dwojaką korzyść, zarówno przyspieszenie obliczeń, jak i lepszą ekonomikę obliczeń (pod względem energetycznym).

## Wykorzystanie komputerów kwantowych w obliczeniowej mechanice płynów<sup>9)</sup>

Firma Ansys interesuje się różnymi nowoczesnymi technologiami informatycznymi, a zwłaszcza sztuczną inteligencją, obliczeniami na superkomputerach oraz komputerami kwantowymi. Z tą ostatnią technologią są związane duże nadzieje na przełomowy postęp. Również w dziedzinie numeryki stawiane są pierwsze kroki na komputerach kwantowych, a zespoły naukowców rozwijają algorytmy, starając się zwiększać precyzję obliczeń<sup>10, 11)</sup>. Z wykorzystaniem technologii firmy Nvidia o nazwie CUDA-Q pisane są programy do rozwiązywania cząstkowych równań różniczkowych, które stanowią podstawę każdego programu obliczeniowej mechaniki płynów. Wspomniana platforma pozwala na rozwijanie hybrydowych rozwiązań, łączenie obliczeń kwantowych z klasycznymi i przyspieszanie obliczeń dzięki wykorzystaniu kart graficznych. Prace na




Fig. 3. *Visualization of the results of a simulation performed using a quantum computer<sup>7)</sup>*

**Rys. 3. Wizualizacja wyników symulacji przeprowadzonej z wykorzystaniem komputera kwantowego<sup>7)</sup>**

razie są na wstępnym etapie. Bada się, jak implementować poprawnie algorytmy, a następnie skalować je do rozmiarów np. symulacji dla przemysłu. Szczególnie 2 cechy systemów kwantowych wydają się atrakcyjne do takich zastosowań. Po pierwsze, to wielowymiarowość, gdyż w odróżnieniu od klasycznych bitów, te kwantowe (zwane kubitami) mogą kodować znacznie większe ilości danych. Klasyczne bity mają skalowanie liniowe, dodatek  $X$  bitów dodaje  $X$  miejsca na dane. W przypadku kubitów wzrost jest eksponentalny, każdy kolejny kubit podwaja przestrzeń na dane. W testowej symulacji zastosowano 39 kubitów, co pozwoliło na przeprowadzenie obliczeń na siatce o 68 mln węzłów, co znacznie przewyższa możliwości klasycznych siatek i bitów. Po drugie, to prostsze zrównoleglenie obliczeń, oprogramowanie kwantowe pozwala na równoległe, jednoczesne aktualizowanie wartości zmiennych we wszystkich węzłach. Komputer kwantowy, ze względu na specyficzną naturę kubitów, potrafi iterować wiele rozwiązań jednocześnie, w odróżnieniu od komputerów klasycznych, które mogą wykonywać tylko jedną iterację na raz. To pozwala na znaczne przyspieszenie obliczeń.

Aby jednak wykorzystać w praktyce te niekwestionowane zalety komputerów kwantowych, konieczne są przeznaczone do tego rozwiązania. Mowa tutaj o specjalnie napisanych algorytmach, które pozwolą zarówno na obliczenia, jak i odczyt oraz zapis z kubitów. Do tego celu opracowano kwantową metodę QLBM (*quantum lattice Boltzmann method*)<sup>12)</sup>.

Obecnie w obliczeniowej mechanice płynów do przeprowadzenia symulacji najczęściej wykorzystuje się iteracyjne rozwiązywanie cząstkowych równań różniczkowych, np. Naviera i Stokesa, z wykorzystaniem metody objętości

skończonej. Metoda QLBM korzysta z mniej popularnego podejścia Lattice Boltzmann. Zamiast rozwiązywać wprost równanie Naviera i Stokesa, modeluje się przemieszczanie płynu między komórkami za pomocą analizy wektorów oddziałujących na wirtualną cząstkę znajdującą się w każdej komórce. To pozwala na obliczanie zderzeń i ruchu tych cząstek, co w skali makroskopowej obserwuje się jako przepływ płynu. Metoda ta pozwala łatwiej symulować np. przepływ cieczy nieściśliwych lub układów wielofazowych (jak przykładowo pęcherze gazu w cieczy) i warstw porowatych. Problemem są symulacje przepływów o wysokich wartościach liczby Knudsen lub liczby Macha. Metoda QLBM jest kwantową adaptacją metody Lattice Boltzmann, dzięki której można wykorzystać potencjał obliczeniowy kubitów. Jej założenia dają się doskonale przekładać na strukturę komputera kwantowego, zapewniając wysoką wydajność algorytmów. Typowy krok obliczeniowy dla modelu QLBM składa się z 4 etapów: (i) wyznaczenie stanu: inicjalizacja wartości w każdej komórce domeny, co odpowiada za skalarnie pole gęstości płynu, (ii) zderzenia: liniowe kombinacje odpowiednich operacji kwantowych pozwalające na wprowadzenie zderzeń, do obliczeń wykorzystuje się dodatkowe kubity pomocnicze, (iii) przepływ: wykorzystanie wektorów prędkości w każdej komórce, aby wyznaczyć przepływ płynu w domenie, oraz (iv) zapisanie wyników: odczytanie wartości z kubitów celem rekonstrukcji rozkładu pola gęstości płynu po zderzeniach i przepływie.

Wykorzystując przedstawioną metodę, firmy Nvidia i Ansys przeprowadziły próbną symulację na superkomputerze Gefion. Kod został najpierw przetestowany na zwykłym komputerze (na procesorach CPU), a następnie przekonwertowany za pomocą środowiska CUDA-Q na kod dla komputera kwantowego. Do obliczeń wykorzystano 39 kubitów (36 posłużyło do przechowywania domeny obliczeniowej, a 3 do wykonywania operacji przepływu i zderzeń). Z powodzeniem przeprowadzono symulację zjawiska przewodzenia-dyfuzji fali sinusoidalnej, w domenie 2-wymiarowej o wielkości 262 144 na 262 144 elementów. Wizualizację otrzymanego pola gęstości zaprezentowano na rys. 3.

## Wykorzystanie sztucznej inteligencji do symulacji

Udostępnienie w sieci ChatGPT (*chatbot* generatywnej sztucznej inteligencji) w listopadzie 2022 r. zmieniło świat. W przeciągu 2 miesięcy aplikacja zyskała 100 mln użytkowników, co czyni ją najszybciej rosnącą aplikacją w historii<sup>13)</sup>. Powstał nawet termin określający to zjawisko: *boom* AI. Na rys. 4 zaprezentowano, jak nagle i intensywnie było to zjawisko, na podstawie wyszukiwań w przeglądarce Google.

Również obliczeniowa mechanika płynów stara się wykorzystać narzędzia sztucznej inteligencji do usprawnienia własnych aplikacji i procesów. Przykładem takiego rozwiązania jest np. AnsysGPT<sup>15)</sup>. Jest to specjalistyczny chatbot wykorzystujący sztuczną inteligencję, aby pomagać użytkownikom,

odpowiadając na pytania o programach obliczeniowych, zagadnieniach fizycznych stosowanych w symulacjach, jak i różnorodnych problemach inżynierskich. Został on wytrenowany na instrukcjach do oprogramowania i różnorodnych materiałach szkoleniowych z zasobów firmy Ansys. Jest to dostępny całą dobę asystent, który może pomagać uporać się z różnymi problemami technicznymi lub inżynierskimi.

Inne znane aplikacje wykorzystujące sztuczną inteligencję także potrafią pomóc podczas przygotowywania symulacji. Często, aby rozszerzyć modelowanie konieczne jest napisanie własnej funkcji lub podprogramu wykonującego požądane obliczenie lub zmieniające warunki brzegowe w niestandardowy sposób. Powszechnie dostępne czatboty (np. Copilot od firmy Microsoft) potrafią w toku rozmowy zaproponować gotowy kod, który można następnie zaimplementować np. jako UDF w programie Ansys Fluent. Należy oczywiście pamiętać o dokładnym zweryfikowaniu odpowiedzi udzielonych przez czatbota. Oznacza to więc, że wiedza i doświadczenie użytkownika nadal pozostają nieodzownym elementem pisania takich dedykowanych rozwiązań. Doskonale obniża to jednak próg wejścia, pomagając odnaleźć się w skomplikowanej składni programów i znakomicie skracając czas potrzebny do stworzenia specjalnie dopasowanych funkcjonalności.

Innym ciekawym pomysłem jest włączenie sztucznej inteligencji w proces przygotowania i przeprowadzenia symulacji<sup>16)</sup>. Od połowy XX w. inżynierowie przeprowadzali różnorodne obliczenia, modelowania i symulacje, zyskując cenne doświadczenie, które rozwiązania się sprawdzają, a które nie. Często jednak przepływ tych informacji jest ograniczony, choćby ze względu na brak możliwości zapoznania się z ogromem wiedzy dostępnej w dzisiejszych czasach. Tutaj z pomocą może przyjść sztuczna inteligencja, która jest w stanie zapoznać się z bazą wiedzy, a następnie na jej podstawie pomagać, podpowiadać i sugerować rozwiązania. Wtedy projekty nie są aż tak silnie zależne od nadzoru inżynierów zajmujących się modelowaniem, co pozwala przyspieszyć proces. Zaleta ta będzie szczególnie wartościowa w przemyśle, gdzie skrócenie czasu projektu często przekłada się na bezpośrednie korzyści finansowe. Wytrenowany asystent SI może również towarzyszyć mniej doświadczonym użytkownikom we wstępnym przygotowaniu symulacji, zdejmując część pracy z doświadczonych pracowników. Wtedy ich cenny czas może być poświęcony na bardziej wymagające zadania. Istnieją również rozwiązania wykorzystujące uczenie maszynowe (np. Ansys SimAI), które uczą się na gotowych, rozwiązanych symulacjach. Dzięki temu są w stanie podpowiadać i przewidywać wyniki bez wykonywania obliczeń. To znakomicie skraca czas potrzebny do modelowania procesu, o ile dysponuje się dużą bazą rzetelnie zweryfikowanych wyników analogicznych symulacji. Przykładem mogłaby być niewielka zmiana geometrii lub wymiarów. Bazując na udostępnionych wynikach, program może przewidzieć wpływ drobnej zmiany na pole temperatury, pozwalając na szybkie prototypowanie. Z pewnością warto potem dokładnie zweryfikować poprawność tego rozwiązania, jednak przy szybkim




Fig. 4. Interest in searching for the term AI between 2005 and 2025<sup>14)</sup>

Rys. 4. Zainteresowanie wyszukiwaniem hasła AI na przestrzeni lat 2005–2025<sup>14)</sup>

prototypowaniu zysk czasu może być znaczny. Często takie podejście sprawdzi się na wczesnym etapie pracy, np. przy przygotowywaniu oferty. Szybka weryfikacja założeń pozwala na przygotowanie rzetelnej i realistycznej propozycji biznesowej. Innym przykładem może być wytwarzanie modeli hybrydowych. Na przykład Jeon i współpr.<sup>17)</sup> zaproponowali połączenie modelu uczenia maszynowego z obliczeniową mechaniką płynów. Sposób ten polega na rozwiązywaniu wstępnych symulacji za pomocą standardowej metody obliczeniowej mechaniki płynów, a następnie uczenia modelu za pomocą wygenerowanych danych. W miarę postępu uczenia wyszkolona sieć neuronowa jest w stanie przyspieszać obliczenia, skutecznie przewidując początkowe rozwiązania, bez potrzeby rozwiązywania pełnych równań różniczkowych.

## Nowe paradygmaty w obliczeniowej mechanice płynów

Dzięki dostępności nowych potężniejszych programów, jak i bardziej wydajnego sprzętu komputerowego, możliwości obliczeniowej mechaniki płynów znacznie się rozwinęły. W związku z tym zmieniły się również możliwości, podejścia i pomysły wynikające z postępu w dziedzinie.

### Symulacje bezsiatkowe. Podejście cząsteczkowe<sup>18–20)</sup>

W niektórych geometriach trudno jest nałożyć siatkę numeryczną o odpowiednio wysokiej jakości ze względu na ostre krawędzie, wąskie przestrzenie i powierzchnie o dużej liczbie szczegółów. Czasem symulowany proces jest złożony i ciężko jest precyzyjnie odwzorować go z wykorzystaniem symulacji za pomocą standardowego podejścia. Właśnie do takich zastosowań powstała metoda SPH (*smoothed-particle hydrodynamics*). Jest to model z podejścia Lagrange'a. Główną różnicą metody SPH od standardowej metody FVM (*finite volume model*) jest odejście od obliczeń w komórkach

siatki (skończonych objętościach, które wypełniają całą geometrię) i skupienie się na pojedynczych elementach płynu poruszających się w obrębie geometrii. Każdy z elementów ma swoje miejsce w przestrzeni, masę, pęd i energię. Może oddziaływać z innymi cząsteczkami, ścianami i siłami objętościowymi, w zgodzie z drugim prawem Newtona. Głównym zastosowaniem modelu SPH są symulacje oddziaływania płynu z cząstkami ciała stałego, w szczególności, w przypadku gdy występuje powierzchnia swobodna płynu (choćby w przypadku zbiorników wypełnionych cieczą<sup>18</sup>). Jest też doskonały w przypadku ruchomych geometrii, takich jak dla symulacji rozbryzgu cieczy, ruchu obrotowego czy przepływu cząstek stałych w płynie. Przykładem zastosowania tego modelu jest np. symulacja rozbijania fal morskich na falochronie, który ma postać zazębających się gwiazdobluków, lub modelowanie procesu mielenia na mokro w młynach kratowych i odśrodkowych. Szczególną korzyścią jest możliwość bezpośredniego modelowania zachowania mielonych cząstek. W standardowej metodzie FVM konieczne byłoby uproszczenie i przybliżenie zachowania fazy stałej. Na rys. 5, będącym zrzutem ekranu z wideo, przedstawiono przekrój młyna półautonomicznego (*SAG mill*), który był obiektem symulacji. Na zielono oznaczono elementy płynu i cząstki stałe, które poruszały się wewnątrz obudowy młyna.

Widoczne na zdjęciu niebieskie cząstki to kule służące do mielenia, elementy brązowe to mielona substancja. Dodatkowo w procesie dozowana jest woda, co narzuca wymagania symulowania oddziaływania cieczy z ciałem stałym. Obliczenia przeprowadzono dla młynów o rzeczywistych rozmiarach (średnica 6,7 m, wypełnienie 31 t materiału). W standardowej metodzie FVM modelowanie tej skali byłoby niemożliwe, choćby ze względu na wymagane zasoby.

### Nowe metody nakładania siatki – metoda Rapid Octree<sup>22, 23</sup>

Tradycyjna procedura nakładania siatki numerycznej (typu *bottom-up*), która potem służy do obliczeń, zakłada najpierw nałożenie siatki na powierzchnie geometrii,




Fig. 5. Picture from video about simulating the work of SAG mill<sup>21</sup>

Rys. 5. Kadr z filmu o symulacji pracy młyna półautonomicznego<sup>21</sup>

a następnie generowanie siatki objętościowej, bazując na tej wytworzonej na powierzchniach. Jest to algorytm, który można precyzyjnie kontrolować, ale przez to wymaga większego nakładu pracy i jest wrażliwy na niedoskonałości geometrii. Jest też słabo skalowalny. Współcześnie często tworzy się ogromne, wielomilionowe siatki, często wymagające rozwiązań wieloskalowych (małych elementów w miejscach np. dużych gradientów i rozrzedzonej tam, gdzie przepływ jest nieistotny lub praktycznie zanikający). Rozwiązaniem tych problemów może być podejście typu *top-down*, jak choćby metoda Rapid Octree. Siatkowanie tą metodą rozpoczyna się od załadowania przygotowanej wcześniej w programie CAD geometrii, teselacji (co powoduje stratę części szczegółów), a następnie nałożeniu zgrubej siatki objętościowej stworzonej z sześciątów. Kształt komórek ma duże znaczenie w przypadku symulacji o charakterze izotropowym, np. wirów (modele typu LES). Następnie siatkę dopasowuje się przy brzegach geometrii poprzez naciąganie i rzutowanie. Niestety, powoduje to utratę części szczegółów powierzchni. Algorytm cały czas dba też o utrzymanie jakości siatki na odpowiednim poziomie. Metoda Rapid Octree najczęściej znajduje zastosowanie w przypadku przepływów zewnętrznych, np. w przypadku aerodynamiki. Metoda ta skaluje się też dużo lepiej, co jest istotne, ponieważ przyszłością symulacji są obliczenia na wielu procesorach CPU lub kartach graficznych GPU, prowadzone w sposób zrównoleglony. Dodatkowo zmniejszona jest ilość pracy użytkownika, np. na przygotowanie geometrii (metoda dopuszcza „brudniejszą” geometrię), czy ustawianie parametrów siatkowania.

### Zwiększanie dostępności modelowania

Na koniec trzeba jeszcze wspomnieć o procesie demokratyzacji modelowania i symulacji. O ile przygotowanie precyzyjnego i rzetelnego modelu dalej wymaga znacznej wiedzy, doświadczenia, a czasem także wycucia, to pewne podstawowe symulacje są coraz prostsze do przeprowadzenia. Naukowcy opracowują uniwersalne modele, które dają dobre rezultaty nawet bez dodatkowej konfiguracji czy dopasowywania ich parametrów. Programy do siatkowania mogą pracować, wykorzystując geometrię przygotowaną w dowolnym programie CAD, a sam proces nakładania siatki jest w coraz większym stopniu zautomatyzowany i ogranicza się czasem do podania pożądanego wymiarów komórek. W ten trend wpisuje się też nowe, zaproponowane przez firmę Ansys rozwiązanie o nazwie Fluent Web UI<sup>24</sup>. Jest to interfejs, który pozwala podłączyć się do aktywnej sesji symulacji za pomocą dowolnej przeglądarki internetowej<sup>25</sup>. To pozwala na podgląd przebiegu obliczeń lub wykonanie na szybko wizualizacji. Rozwiązanie to nie obciąża komputera użytkownika i wszel-

kie operacje wymagające mocy obliczeniowej pozostają po stronie komputera, na którym uruchomiona jest symulacja. Do jednej sesji symulacji może przyłączyć się nawet kilku użytkowników, co pozwala na dużą elastyczność w pracy. Zdalny dostęp może się okazać przydatny np. podczas spotkania z klientem lub do sprawdzania postępu prac bez konieczności obecności przy stacji roboczej.

## Podsumowanie i wnioski

Rozwój w sferze informatycznej postępuje nieubłaganie. Nikt nie może pozwolić sobie na pozostanie w tyle, pod rygorem utraty swojego miejsca na rynku oraz znaczenia i pozycji. Dziedzina obliczeniowej mechaniki płynów nie jest pod tym względem wyjątkowa. Pozostawanie na bieżąco z nowinkami z branży pozwala na szybsze przygotowanie symulacji, precyzyjniejsze modelowanie i zmniejszenie wymaganego nakładu pracy. To przekłada się na oszczędności czasu i pieniędzy dzięki optymalizacji procesów, przyspieszeniu prototypowania i skróceniu procesu badawczo-rozwojowego. Postępy pozwalają też na przeprowadzenie symulacji dla niedostępnych wcześniej procesów, przekładając się na zwiększenie bezpieczeństwa.

W pracy przedstawiono, jakie technologie obecnie rozwijane są w branży modelowania z wykorzystaniem obliczeniowej mechaniki płynów. Zapoznanie się z takim przeglądem pozwala na bardziej świadome podejmowanie decyzji i wyznaczanie kierunku rozwoju zarówno w biznesie, jak i w nauce. O ile niektóre technologie, takie jak np. komputery kwantowe, są jeszcze we wczesnej fazie rozwoju, to warto już dziś szykować się na przełom, jaki wprowadzą. Z kolei świadomość, że przyspieszanie symulacji opiera się teraz głównie na wykorzystaniu superkomputerów, składających się nie tylko z procesorów CPU, ale również potężnych jednostek GPU, pozwala na podjęcie przemyślnych, przyszłościowych decyzji podczas zakupu lub wynajmu sprzętu obliczeniowego. Zapoznanie się z nowymi technikami i paradygmatami, jak choćby modelowaniem bezsiatkowym, pozwala na poszerzenie horyzontów i zmianę punktu widzenia, a w konsekwencji otworzenie się na modelowanie i rozwój procesów, które niegdyś pozostawały poza naszym zasięgiem.

Analiza obecnie rozwijanych technologii nasuwa też myśl, jakie będą kolejne kroki. Na pewno postępować będzie wykorzystanie sztucznej inteligencji jako asystenta pomagającego w procesie, ale też do tworzenia wytrenowanych, specjalistycznych solverów, które przyspieszą modelowanie. Spodziewany jest również rozwój narzędzi pod kątem aplikacyjności, tak aby można było skrócić czas wdrożenia, symulować pełne procesy przemysłowe oraz upraszczać poszczególne etapy w procesie modelowania. Rozwój możliwości sprzętowych zdaje się spowalniać. W związku z tym na znaczeniu zyskiwać zacznie optymalizacja procesów, ale także kodu komputerowego wykorzystywanego do obliczeń. W przypadku superkomputerów

dochodzi się też do granicy skalowania. Dodawanie większej ilości CPU lub GPU nie powoduje już przyspieszenia obliczeń ze względu na rosnące opóźnienia w komunikacji między jednostkami. Dlatego właśnie optymalizacja może stać się ważnym kierunkiem rozwoju.

Otrzymano: 03-03-2026

Zrecenzowano: 05-05-2026

Zaakceptowano: 08-05-2026

Opublikowano: 25-05-2026

## LITERATURA

- [1] G.E. Moore, *Proc. IEEE* 1998, **86**, nr 1, 82, doi.org/10.1109/JPROC.1998.658762.
- [2] [https://en.wikipedia.org/wiki/Moore%27s\\_law](https://en.wikipedia.org/wiki/Moore%27s_law), dostęp 17.02.2026 r.
- [3] J. McKenzie, Moore's law: further progress will push hard on the boundaries of physics and economics, <https://physicsworld.com/a/moores-law-further-progress-will-push-hard-on-the-boundaries-of-physics-and-economics/>.
- [4] Shaping the Future of Scalable Engineering at Supercomputing 2025, <https://www.ansys.com/blog/shaping-future-scalable-engineering-supercomputing-2025>.
- [5] Fluent user's guide. 38.10. Fluent GPU solver limitations, [https://ansyshelp.ansys.com/public/account/secured?returnurl=/Views/Secured/corp/v252/en/flu\\_ug/flu\\_ug\\_sec\\_gpu\\_solver\\_limitations.html?q=Fluent%20GPU%20Solvent%20Limitations](https://ansyshelp.ansys.com/public/account/secured?returnurl=/Views/Secured/corp/v252/en/flu_ug/flu_ug_sec_gpu_solver_limitations.html?q=Fluent%20GPU%20Solvent%20Limitations).
- [6] D. Gou, Y. Shen, *Chem. Eng. Sci.* 2024, **299**, 120536, <https://doi.org/10.1016/j.ces.2024.120536>.
- [7] J. Yu, S. Wang, K. Luo, J. Fan, *Powder Technol.* 2024, **437**, 119475, <https://doi.org/10.1016/j.powtec.2024.119475>.
- [8] A. Rafiev, M.A.N. Al-Hayanni, F. Xia, R. Shafik, A. Romanovsky, A. Yakovlev, *IEEE Trans. Multi-Scale Comput. Syst.* 2018, **4**, nr 3, 436, doi.org/10.1109/TMSCS.2018.2791531.
- [9] Scaling Quantum Computing Research to a New Milestone, <https://www.ansys.com/blog/scaling-quantum-computing-research>.
- [10] Z.-Y. Chen, T.-Y. Ma, C.-C. Ye, L. Xu, W. Bai, L. Zhou i in. *Comput. Methods Appl. Mech. Eng.* 2024, **432**, 117428, <https://doi.org/10.1016/j.cma.2024.117428>.
- [11] M. Lee, Z. Song, S. Kocherla, A. Adams, A. Alexeev, S.H.A. Bryngelson, *Future Gener. Comput. Syst.* 2026, **174**, 107975, <https://doi.org/10.1016/j.future.2025.107975>.
- [12] A. Tiwari, J. Iaconis, J. Jojo, S. Ray, M. Roetteler, C. Hill, J. Pathak, *arXiv* 2025, <https://doi.org/10.48550/arXiv.2504.10870>.
- [13] ChatGPT reaches 100 million users two months after launch, <https://www.theguardian.com/technology/2023/feb/02/chatgpt-100-million-users-open-ai-fastest-growing-app>.
- [14] [https://en.wikipedia.org/wiki/AI\\_boom](https://en.wikipedia.org/wiki/AI_boom).
- [15] Ansys AI, <https://www.ansys.com/ai>.
- [16] The Intersection of AI and Simulation Technology, <https://www.ansys.com/blog/simulation-and-ai>.
- [17] J. Jeon, J. Lee, R. Vinuesa, S.J. Kim, *Int. J. Heat Mass Transf.* 2024, **220**, 124900, <https://doi.org/10.1016/j.ijheatmasstransfer.2023.124900>.
- [18] Z. Cai, A. Topa, L.P. Djukic, M.T. Herath, G.M.K. Pearce, *Ocean Eng.* 2021, **236**, 109556, <https://doi.org/10.1016/j.oceaneng.2021.109556>.
- [19] Smoothed-particle Hydrodynamics and DEM: A Powerful Solution to Simulate Solid-fluid Applications, <https://www.ansys.com/blog/what-is-sph-simulation>.
- [20] A. Amicarelli, *Int. J. Comput. Fluid Dyn.* 2024, **38**, nr 5, 339, <https://doi.org/10.1080/10618562.2025.2469497>.
- [21] PL Grate Discharge Slurry Flow within a SAG Mill, <https://www.youtube.com/watch?v=rTHASQ5cnZA>.
- [22] Fluent User's Guide - Generating Rapid Octree Meshes, 2025, [https://ansyshelp.ansys.com/public/account/secured?returnurl=%2FViews%2FSecured%2Fcorp%2Fv252%2Fen%2Fflu\\_ug%2Ftgd\\_user\\_octree\\_mesh.html%3Fq%3Drapid%20octree](https://ansyshelp.ansys.com/public/account/secured?returnurl=%2FViews%2FSecured%2Fcorp%2Fv252%2Fen%2Fflu_ug%2Ftgd_user_octree_mesh.html%3Fq%3Drapid%20octree).
- [23] G.J. Page, *Aeronaut. J.* 2013, **117**, nr 1188, 133, <https://doi.org/10.1017/S0001924000007910>.
- [24] New Ansys Fluent Web UI Supports Access to Massive, Multi-GPU CFD Simulations, <https://www.ansys.com/news-center/press-releases/2-7-24-ansys-fluent-web-ui-supports-access-to-massive-cfd-simulations>.
- [25] Fluent User's Guide - Introduction to Ansys Fluent's Web Interface, 2025, [https://ansyshelp.ansys.com/public/account/secured?returnurl=%2FViews%2FSecured%2Fcorp%2Fv252%2Fen%2Fflu\\_ug%2Fflu\\_ug\\_sec\\_web\\_overview.html](https://ansyshelp.ansys.com/public/account/secured?returnurl=%2FViews%2FSecured%2Fcorp%2Fv252%2Fen%2Fflu_ug%2Fflu_ug_sec_web_overview.html).