

## **Naukowe zarządzanie danymi w chmurze: przegląd technologii, podejść i wyzwań**

Nauki eksperymentalne tworzą ogromne ilości danych. W astronomii oczekuje się, że dane uzyskane w ramach projektu Pan-STARRS (projekt Pan-STARRS, 2010) będą dawać więcej niż petabajt obrazów rocznie. W fizyce wysokich energii Wielki Zderzacz Hadronów będzie generował 50-100 petabajtów danych każdego roku, przy czym około 20 PB tych danych będzie przechowywanych i przetwarzanych w światowej federacji krajowych sieci łączących 100 000 procesorów (projekt Duży Zderzacz Hadronów, 2010). Przetwarzanie w chmurze jest niezwykle atrakcyjne dla społeczności naukowej, która coraz częściej postrzega ją jako część rozwiązania radzenia sobie z rosnącą ilością danych. Przetwarzanie w chmurze umożliwia uzyskanie korzyści skali w projektowaniu obiektów i budowie sprzętu. Grupy użytkowników mogą hostować, przetwarzać i analizować duże ilości danych z różnych źródeł. Istnieje kilku dostawców oferujących platformy przetwarzania w chmurze; należą do nich Amazon Web Services (Amazon Web Services, 2010), Google App Engine (Google App Engine, 2010), AT&T Synaptic Hosting (AT&T Synaptic Hosting, 2010), Rackspace (Rackspace, 2010), GoGrid (GoGrid, 2010) i AppNexus (AppNexus, 2010). Dostawcy ci obiecują pozornie nieskończone ilości mocy obliczeniowej i pamięci masowej, które mogą być udostępniane na żądanie, w modelu cenowym płacisz tylko za to, czego używasz. Społeczność naukowa ma duże doświadczenie w rozwiązywaniu problemów związanych z zarządzaniem danymi w rozproszonych środowiskach obliczeniowych. Siatki danych), oparte na paradygmacie przetwarzania siatkowego, zapewniają przechowywanie danych naukowych na dużą skalę z obsługą wykrywania i dostępu do danych za pośrednictwem sieci grid. Podobnie wiele cyberinfrastruktur i bram zapewnia własne schematy zarządzania danymi na dużą skalę, aby spełnić wymagania specyficzne dla domeny. Zarządzanie danymi naukowymi w chmurze różni się od wcześniejszych podejść w kilku aspektach. Po pierwsze, przetwarzanie w chmurze konsoliduje możliwości obliczeniowe i przechowywanie danych w bardzo dużych centrach danych lub lokalnych centrach danych zorientowanych na ekonomię. W konwencjonalnych obliczeniach o wysokiej wydajności naukowcy dzielą masowo równoległe superkomputery. Dostęp do tych zasobów superkomputerowych jest zarządzany przez systemy kolejek wsadowych. Obliczeniowe dane wejściowe i wyjściowe są przemieszczane w przód i w tył z węzłów obliczeniowych do magazynu danych, który znajduje się oddzielnie. W chmurze obliczeniowej przechowywanie danych i możliwości obliczeniowe znajdują się w tym samym miejscu. Prowadzi to do zmiany paradygmatu w wielu procesach przetwarzania i analizy danych. Po drugie, przechowywanie danych w scentralizowanym obiekcie może być katalizatorem udostępniania danych w różnych dziedzinach naukowych. Przykład multidyscyplinarnego hostingu danych można znaleźć w otwartej bazie danych SciDB. SciDB ma służyć naukowcom z różnych dyscyplin, w tym astronomii, biologii, meteorologii, oceanografii i fizyki. Dzielenie się to nie tylko między różnymi dziedzinami, ale także między naukowcami z różnych instytucji tej samej dyscypliny. Wreszcie, z punktu widzenia hostingu danych, przetwarzanie w chmurze jest z natury bardziej zrównoważone. W ustawieniach chmury dane są często replikowane, aby poradzić sobie z przejściowymi i trwałymi awariami, a także z uszkodzeniem danych spowodowanym użyciem zwykłego sprzętu. Ponieważ ochrona danych jest często krytycznym aspektem w większości dziedzin naukowych, zarządzanie danymi w chmurze jest często znacznie lepszą alternatywą dla lokalnej pamięci masowej, co wiązałoby się z rozwiązywaniem problemów technicznych, które obejmują między innymi replikację, odporność na błędy i wykrywanie błędów.

### **Zagadnienia zarządzania danymi w ramach eksperymentów naukowych**

Zarządzanie danymi w informatyce naukowej obejmuje przechwytywanie danych, przechowywanie i analizę zbiorów danych. Wiele z tych danych pochodzi z instrumentów obserwacyjnych lub eksperymentalnych, takich jak teleskopy przeglądowe, radary dopplerowskie, satelity i akceleratory cząstek, takie jak Wielki Zderzacz Hadronów. Zbieranie dużych ilości danych z instrumentów, te mogą

czasami powodować problemy w fazach pobierania i przesyłania danych. Integracja danych z różnych źródeł danych również stanowiła wyzwanie ze względu na różnice we wzorcach dostarczania danych, a także niejednorodność formatów danych. Ponadto dane są również wytwarzane w fazie obliczeń i podczas przebiegów symulacji. Ponadto, oprócz danych eksperymentalnych (surowych, pochodnych i rekombinowanych), wszelkie wyniki i publikacje powstałe w wyniku tych eksperymentów są również gromadzone i zarządzane jako część danych naukowych. Analiza i symulacja danych często wiąże się z wizualizacją. Zebrane dane są na ogół przechowywane przed udostępnieniem ich w procesie analizy lub wizualizacji danych. Proces selekcji obejmuje wydajną ekstrakcję informacji oprócz organizacji danych, w tym indeksowania i replikacji. Powiązaną kwestią jest długoterminowe przechowywanie zgromadzonych danych. Poszczególne etapy przetwarzania danych naukowych są realizowane nie tylko sekwencyjnie, ale także rekurencyjnie i interaktywnie z innymi etapami eksperymentów naukowych. Przetwarzanie danych często wiąże się z dynamicznym udostępnianiem między naukowcami lub grupami. Na przykład Unidata publikuje publicznie dane z obserwacji atmosferycznych (Unidata, 2010); a w dziedzinie biotechnologii NCBI (NCBI, 2010) publikuje informacje, które obejmują sekwencje genów i struktury chemiczne, oprócz udostępniania biblioteki artykułów biomedycznych.

### **Chmury danych: nowe technologie**

Zbiory danych w skali Peta stawiają nowe wyzwania. Tutaj system plików musi być w stanie zarządzać miliardami plików, z których niektóre mogą mieć długość kilku terabajtów. Aby sobie z tym poradzić, zaproponowano syntezę systemów baz danych i systemów plików; tutaj hierarchia plików została zastąpiona bazą danych zawierającą różne atrybuty każdego pliku. Model programowania Map-Reduce firmy Google umożliwia równoczesne przetwarzanie obszernego zbioru danych na dużej liczbie maszyn. Obliczenia i dane, na których operują, są umieszczone na tej samej maszynie. W związku z tym obliczenia muszą jedynie wykonać operacje wejścia/wyjścia na dysku lokalnym, aby uzyskać dostęp do danych wejściowych. Map-Reduce można również traktować jako przykład modelu SPMD w obliczeniach równoległych. System plików Google (GFS) dość dobrze pasuje do modelu programowania Map-Reduce. GFS rozprasza duży plik na zestawie maszyn, z których każda ma własne standardowe dyski twarde: w ten sposób fragmenty pliku znajdują się na wielu komputerach, gdzie obliczenia Map-Reduce byłyby przesyłane podczas późniejszego przetwarzania. Aby uwzględnić awarie, które występują dość często w ustawieniach dotyczących składników towarowych, GFS replikuje każdy plik (wartość domyślna to 3). Zakłada się, że awarie są trwałe, a gdy system wykryje awarię, działa w celu zapewnienia, że części plików, które były hostowane na uszkodzonym komputerze, zostaną zreplikowane w innym miejscu (przy użyciu kopii z innych komputerów), aby zapewnić, że poziomy replikacji dla dotkniętych plików są zachowane. Aby zapewnić dostęp do danych przechowywanych w GFS podobny do bazy danych, Google opracował rozproszony magazyn danych, BigTable. BigTable zapewnia wielowymiarową mapę posortowaną według {wiersza, kolumny, znacznika czasu}. Pliki są zgrupowane jako tablety o rozmiarze 100 × 200 MB, a BigTable zarządza więcej niż kilkoma tabletami Giga. Implementacja Google jest publicznie dostępna za pośrednictwem Google Application Engine (Google App Engine, 2010). Google zapewnia również infrastrukturę analizy danych Sawzall, która efektywnie wykorzystuje duże klastry obliczeniowe z dużymi zbiorami danych. Sawzall pozwala użytkownikom określić instrukcje wykonania za pomocą instrukcji i wyrażeń zapożyczonych z C, Java lub Pascal. Sawzall następnie konwertuje te instrukcje w program, który może działać w wysoce równoległym klastrze Google. Wysiłki Google zainspirowały kilka projektów open source, takich jak Hadoop (Hadoop, 2010) i kilka projektów pochodnych, w tym HBase (HBase, 2010), Hypertable (Hypertable, 2010) i Hive (Hive, 2010). Hadoop zapewnia środowisko programistyczne Map-Reduce oparte na rozproszonym systemie plików Hadoop (HDFS). HBase i Hypertable wykorzystują Hadoop do wdrożenia rozproszonego sklepu, który odzwierciedla projekt oprogramowania BigTable Google. Apache's Hive (Hive, 2010) to infrastruktura hurtowni danych, która umożliwia podobne do SQL

zapytania ad hoc danych przechowywanych w HDFS. Zookeeper (Zookeeper, 2010) to wysokowydajna usługa koordynacji dla aplikacji rozproszonych. Cassandra, opracowana przez Facebook i Yahoo, zapewnia rozproszony magazyn kolumn do zarządzania danymi w skali internetowej. Cassandra koncentruje się na odporności na awarie, aby uzyskać funkcję „zawsze zapisywalną”, co ma kluczowe znaczenie w przypadku niektórych programów internetowych. Pig to platforma do analizy dużych zbiorów danych. Pig jest zarówno wysokopoziomym językiem przepływu danych, jak i ramami wykonawczymi do obliczeń równoległych. Pig automatycznie tłumaczy zapytania użytkowników na wydajne plany oceny równoległej, a następnie koordynuje ich wykonanie w klastrze Hadoop. Pig wykorzystuje język Pig Latin, opracowany przez Yahoo, który łączy deklaratywne zapytania wysokiego poziomu w duchu SQL oraz niskopoziomowe, proceduralne programowanie MapReduce. Podobnie firma Microsoft udostępnia klientom DataCloud własny stos oprogramowania i zaplecze obliczeniowe. Azure (Microsoft, Windows Azure, 2010) to system rozproszonej pamięci masowej na dużą skalę w tym stosie oprogramowania. SQL Azure (Microsoft, SQL Azure, 2010) zapewnia rozproszony magazyn kluczwartość, a jego interfejs rozszerza standardowy SQL. Firma Microsoft korzysta z modelu przetwarzania opartego na wykresie przepływu danych o nazwie Dryad, który jest przeznaczony dla klastrów chmurowych opartych na systemie Windows. DryadLINQ wykorzystuje LINQ (Language Integrated Query), aby zapewnić hybrydę programowania deklaratywnego i imperatywnego. Do obliczeń rozproszonych za pomocą DryadLINQ można użyć dowolnego języka programowania obsługującego LINQ, takiego jak C#, VB i SQL. DryadLINQ zbudowany na górze na Dryad, zapewnia język sekwencyjnej analizy danych. System DryadLINQ w przejrzysty sposób tłumaczy fragmenty programu, które są równoległe do danych, na rozproszony plan wykonania, który jest następnie przekazywany do platformy wykonawczej Dryad.

Obiekty w zestawach danych DryadLINQ mogą być dowolnego typu .NET; ułatwia to pracę z zestawami danych, takimi jak poprawki obrazów, wektory i macierze. W przeciwieństwie do Google i Microsoft, usługi internetowe Amazon (Amazon Web Services, 2010) zapewniają znacznie niższy poziom infrastruktury obliczeniowej i przechowywania danych. Ponadto dostępna jest również usługa sieciowa Elastic Map-Reduce (Amazon Elastic MapReduce, 2010) oparta na platformie Hadoop. Użytkownicy mogą uruchomić własny klaster wirtualny z określonym przetwarzaniem wsadowym, takim jak Open PBS (2010), Open MPI (2010) lub Condor. Podobnie w klastrze EC2 dostępnych jest kilka komercyjnych systemów zarządzania bazami danych, w tym IBM DB2 (Baru i in., 1995), Microsoft SQL Server (Microsoft, SQL Azure, 2010) oraz Baza danych Oracle 11g (Baza danych Oracle 11g, 2010). Użytkownicy mają dostęp do usług pamięci masowej, takich jak Simple Storage Service (S3) i Elastic Block Service (EBS) (Amazon EBS, 2010). W S3 użytkownicy przechowują obiekty o wielkości 1 bajt ~ 5 GB, do których dostęp uzyskuje się poprzez interfejs usługi sieciowej. EBS zapewnia znacznie większą pamięć masową 1 GB~ 1 TB, a ten blok jest montowany na instancji użytkownika. Amazon zapewnia interfejs usługi internetowej dla prostych funkcji bazy danych, takich jak indeksowanie i zapytania za pomocą SimpleDB (Amazon SimpleDB, 2010). Ostatnio Amazon wprowadził bardziej w pełni funkcjonalne instancje baz danych SQL, takie jak Relational Database Service (RDS) (Amazon RDS, 2010). Tabela 22.1 poniżej podsumowuje różne technologie chmury danych, które omówiliśmy do tej pory. Wiele technologii umożliwiających chmurę danych zostało zbadanych w ostatnich projektach zarządzania danymi rozproszonymi. Projekt Boxwood firmy Microsoft zapewnia rozproszony system zarządzania danymi, który zapewnia rozproszone blokowanie, klastrowanie i przechowywanie danych w oparciu o B-drzewa. Projekt Boxwood ma na celu zapewnienie infrastruktury do budowy usług wysokiego poziomu, takich jak systemy plików lub bazy danych. W dziedzinie ustrukturyzowanych systemów peer-to-peer kilka projektów opartych na rozproszonych tablicach mieszających (DHT) zajmowało się podobnymi problemami dostarczania rozproszonej pamięci masowej lub usług wyższego poziomu w sieciach rozległych. Te projekty oparte na DHT obejmują CAN, Chord, Tapestry

oraz Pastry. Ponadto kilku dostawców baz danych opracowało równoległe bazy danych, które mogą przechowywać duże ilości danych. Baza danych Oracle Real Application Cluster (Oracle Real Application Cluster, 2010) wykorzystuje dyski współdzielone do przechowywania danych i rozproszonego menedżera blokad. IBM DB2 Parallel Edition opiera się na architekturze współdzielonej podobnej do BigTable. Każdy serwer DB2 odpowiada za podzbiór wierszy w tabeli, który przechowuje w lokalnej relacyjnej bazie danych. Te podejścia zapewniają kompletny model relacyjny z transakcjami.

### **Studia przypadków: Wykorzystanie chmury danych do naukowego zarządzania danymi**

W ostatnim dziesięcioleciu pojawiły się nowe wyzwania w dziedzinie obliczeń naukowych. Ilości danych stanowią podstawę kilku z tych wyzwań. Bardzo często naukowcy dziedzinowi pracują z zestawami danych w kolejności terabajtów. Z tego samego powodu często zdarza się, że wolumeny danych są rzędu petabajtów. Problemy wynikają z faktu, że czasy dostępu i szybkości transferu dla standardowych dysków twardych nie nadążają za poprawą ich pojemności. Część tego wynika z elektromechanicznej natury tych napędów dyskowych. Problemy są dodatkowo pogłębiane przez fakt, że jednoczesne przetwarzanie tych zbiorów danych również staje się intensywnie obliczeniowo. Dla zbioru  $N$  punktów danych złożoność przetwarzania może być superliniowa. Przetwarzanie danych może również wiązać się z wielokrotnym dostępem do bazowych zbiorów danych. Istnieje kilka aplikacji naukowych, które wykorzystują technologie chmury danych, aby sprostać wyzwaniom związanym z intensywnym przetwarzaniem danych.

### **Dane Pan-STARRS z GrayWulf**

Projekt Pan-STARRS (projekt Pan-STARRS) to duży przegląd astronomiczny. W projekcie wykorzystany zostanie specjalny teleskop na Hawajach z kamerą 1,4 gigapiksela do pobierania próbek nieba przez okres czterech lat. Duże pole widzenia i stosunkowo krótkie ekspozycje umożliwią teleskopowi pokrycie trzech czwartych nieba 4 razy w roku w 5 kolorach optycznych. Daje to więcej niż petabajt obrazów rocznie. Obrazy zostaną następnie przetworzone przez system segmentacji obrazu, który zidentyfikuje poszczególne detekcje z częstotliwością 100 milionów detekcji na noc. Te detekcje będą powiązane z fizycznymi obiektami na niebie i załadowane do bazy danych projektu w celu dalszej analizy i przetwarzania. Oczekuje się, że baza danych będzie zawierać ponad 5 miliardów obiektów i ponad 100 miliardów detekcji. Przewidywany rozmiar bazy danych to 30 terabajtów do końca pierwszego roku, a pod koniec roku 4 wzrośnie do 80 terabajtów. Uniwersytet współpracuje z firmą Microsoft External Research w celu opracowania zestawu usług programowych i zasad projektowania znanych jako GrayWulf, które opierają się na wykorzystaniu standardowego sprzętu, Windows HPC Server 2008 i Microsoft SQL Server 2008. GrayWulf jest rozszerzeniem klastra Beowulf i zapewnia dostęp do chmury z pulpitu użytkownika. GrayWulf zapewnia udostępniony magazyn danych z możliwością zapytań dla użytkowników, którzy wykonują analizy na udostępnionej bazie danych. W celu uzyskania skalowalności udostępniona baza danych jest podzielona na partycje i warstwy hierarchiczne. Dolna warstwa danych zawiera pionowe partycje tabel i obejmuje trzy typy tabel: Wykrycia, Obiekty i Metadane. Wiersze wykrywania odpowiadają źródłom astronomicznym wykrytym na pojedynczych lub nałożonych na siebie obrazach. Wiersze obiektów odpowiadają unikalnym źródłom astronomicznym i podsumowują statystyki z detekcji pojedynczych i stosowych, które są przechowywane odpowiednio w różnych zestawach kolumn. Metadane odnoszą się głównie do informacji o teleskopach i obrazach. Ogólnie rzecz biorąc, ta partycja danych jest powiązana z określoną częścią nieba. Poza magazynem danych niższego poziomu serwery ładujące/ładcące pobierają nowe wykrycia do codziennej bazy danych. Każdy użytkownik otrzymuje własną bazę danych (MyDB) na serwerach do przechowywania wyników pośrednich. Użytkownicy mają pełną kontrolę nad własnymi bazami MyDB. Dane mogą być przesyłane do lub pobrane z MyDB, a tabele można udostępniać innym użytkownikom: tworzy to środowisko współpracy do udostępniania wyników.

GrayWulf wykorzystuje przepływy pracy do kilku działań związanych z analizą danych. Infrastruktura przepływu pracy Data Valet obejmuje zestaw usług do wizualnej kompozycji przepływu pracy, automatycznego przechwytywania pochodzenia, planowania, monitorowania i obsługi błędów. Oprócz projektu Pan-STARR, inne projekty zarządzały swoimi dużymi zbiorami danych za pomocą GrayWulf.

### **GEON Workflow z klastrem CluE**

San Diego Super Computing Center (SDSC) (San Diego Supercomputing Center, 2010) utworzyło swoją witrynę Data Central, która zawiera 27 PB danych i ponad 100 konkretnych baz danych. W 2009 roku SDSC rozpoczęło badanie hostingu bardzo dużych zbiorów danych w klastrze Academic Cluster Computing Initiative, który jest wspólnym wysiłkiem IBM/Google. Badania skoncentrują się na wykorzystaniu równoległej aplikacji GEON LiDAR Workflow .

### **SciDB**

SciDB (SciDB, 2010) został zainicjowany w ramach dwóch kolejnych warsztatów Extremely Large Databases (XLDB) (XLDB, 2007; XLDB, 2008), które zostały zorganizowane w celu sprostania wyzwaniu, jakim jest zaprojektowanie baz danych, które mogą obsługiwać złożoność i skalę zastosowań naukowych . Przechowywanie danych i obliczenia skalują się równomiernie w SciDB. Przechowywanie danych w SciDB można skalować do kilku petabajtów. Użytkownicy mogą uzyskać dostęp do chmury z 10 000 węzłów, używając laptopa do przetwarzania (podzbioru) zestawu danych. Zgłoszone przypadki użycia SciDB obejmują takie dziedziny, jak astronomia optyczna, radioastronomia, teledetekcja Ziemi, obserwacje i modelowanie środowiska oraz seismologia (SciDB, 2010). SciDB zawiera wsparcie dla tablic i wektorów. Te typy danych mają kilka wbudowanych zoptymalizowanych operatorów, które można sklasyfikować jako strukturalne lub zależne od zawartości. Jak sama nazwa wskazuje, operatory strukturalne operują na strukturze tablicy niezależnie od danych. Przykłady operatorów strukturalnych to Podpróbka i Przekształć. Operator Subsample przyjmuje jako dane wejściowe tablicę A i predykat określony na wymiarach A. Następnie operator generuje nową tablicę z taką samą liczbą wymiarów jak A, ale w której wartości wymiarów spełniają określony predykat (np. co dziesiąty wartość wymiaru). Reshape to bardziej zaawansowany operator strukturalny. Reshape może przekonwertować tablicę na nową z inną liczbą wymiarów, prawdopodobnie z nowymi nazwami wymiarów, ale z taką samą liczbą komórek. Operatory zależne od zawartości to te, których wynik zależy od danych przechowywanych w tablicy wejściowej. Filtr jest jednym z takich operatorów, który przyjmuje jako dane wejściowe tablicę A i predykat P nad wartościami danych przechowywanymi w komórkach A i zwraca tablicę o takich samych wymiarach jak A. Ponadto SciDB obsługuje niepewne dane; tutaj „niepewny x” dla dowolnego typu danych x używa dwóch wartości. Funkcja ta jest szczególnie przydatna przy obliczaniu wyniku obliczenia lokalizacji obserwowanych obiektów powszechnie stosowanych w bazach danych astronomicznych i GIS, które mogą zawierać pewne błędy aproksymacji spowodowane kalibracją sprzętową. SciDB kładzie szczególny nacisk na zarządzanie pochodzeniem danych naukowych. Oczekuje się, że większość danych będzie przesyłana do SciDB ze źródeł wejściowych, takich jak naukowe urządzenia pomiarowe lub czujniki. Ze względu na duże ilości danych dane muszą być zapisywane w zasobnikach dyskowych, które będą zawierać prostokątne fragmenty tablicy. Struktura danych R-Tree służy do śledzenia lokalizacji i zawartości tych wiader.

### **Analiza danych astrofizycznych za pomocą Pig/Hadoop**

Loebman i inni zbadali pojawiające się potrzeby w zakresie zarządzania danymi grupy „N-body Shop”, która specjalizuje się w opracowywaniu i wykorzystywaniu symulacji wielkoskalowych, w szczególności „kodów drzewa N-ciał”. Celem tych symulacji jest zbadanie powstawania i ewolucji wielkoskalowych struktur we wszechświecie. Sklep N-body na Uniwersytecie Waszyngtońskim reprezentuje aktualny stan wiedzy w astrofizycznej symulacji kosmologicznej. W 2008 roku N-body Shop był 10. największym

konsumentem czasu NSF Teragrid, zużywając 7,5 miliona godzin pracy procesora i generując 50 terabajtów surowych danych, z dodatkowymi 25 terabajtami informacji po przetworzeniu. N-body Shop wypróbował różne podejścia do rozwiązywania problemów związanych z zarządzaniem obszernymi zbiorami danych generowanymi podczas symulacji. Wysiłki koncentrowały się na poprawie skalowalności w pamięci RAM i przepustowości we/wy. TIPSYP (TIPSY, 2010) jest jednym z popularnych zestawów narzędzi w tej dziedzinie i zawiera kilka skryptów napisanych w językach interpretowanych, takich jak Python, Perl czy Interactive Data Language (IDL) (IDL, 2010). Cechą wspólną tych narzędzi jest to, że działają w pamięci głównej. W społeczności astrofizycznej, Ntropy, biblioteka równoległa do analizy ogromnych zbiorów danych cząstek została wykorzystana do sprostania potrzebom pamięci rozproszonej. DBMS i frameworki, takie jak Hadoop i Dryad, oferują podobną skalowalność jak biblioteki specyficzne dla aplikacji pod względem wykorzystania pamięci rozproszonej. Jednak naukowcy odnoszą znaczne korzyści z języków deklaratywnych zbudowanych na tych platformach, takich jak Pig Latin i DryadLINQ. Praca Loebmana oceniła wydajność zapytań do analizy danych między DBMS a środowiskami Hadoop/Pig. W przypadku DBMS ta ocena podzieliła dane na partycje w procesie optymalizacji. W przypadku Hadoop/Pig partycjonowanie danych zostało wykonane ręcznie. W eksperymentach, dla większej liczby węzłów, Hadoop/Pig wykazał krótsze czasy odpowiedzi na zapytania do analizy danych. Podobnie zbadali zastosowanie MapReduce do obciążeń przetwarzania danych przestrzennych i potwierdzili doskonałą skalowalność MapReduce w tej dziedzinie. Palankar i inno ocenili Amazon S3 jako wykonalną i opłacalną alternatywę dla hostowania zbiorów danych naukowych, szczególnie tych stworzonych przez duże społeczności, takie jak LSST (LSST, 2009).

### **Hosting danych publicznych przez Amazon Web Services**

Amazon Web Services (AWS) przechowuje publiczne zbiory danych (Amazon Public Datasets, 2010) w swoim scentralizowanym repozytorium publicznych zbiorów danych, które można łatwo zintegrować z aplikacjami opartymi na chmurze AWS. Obecnie użytkownicy mogą uzyskać dostęp do różnych zbiorów danych naukowych, takich jak sekwencje DNA z GenBank, dane genomu ludzkiego, wirus grypy, w tym zaktualizowane sekwencje świńskiej grypy opublikowane przez NCBI, podzbiór Sloan Digital Sky Survey DR6 oraz codzienne globalne pomiary pogody (1929–2009). Użytkownicy mogą tworzyć własne woluminy Elastic Block Service (EBS) z migawką wybranego zestawu danych oraz uzyskiwać dostęp, modyfikować i wykonywać obliczenia na swoich instancjach maszyn wirtualnych.

### **Integracja z modelem programowania obiektowego**

Integrację systemów baz danych z modelem programowania obiektowego można uznać za jeden ze znaczących postępów w technologii baz danych. Istnieje wiele baz danych zorientowanych obiektowo, które traktują dowolny typ danych jako typ hermetyzowany, który można przechowywać jako wartość w polu rekordu. Takie podejście praktycznie rozwiązuje problem braku typów danych w systemach typu bazodanowego. Zapewnia to również łatwy w użyciu interfejs dla środowiska programistycznego. Obecne systemy chmury danych nie określają w odpowiedni sposób, czy ich podejścia w naturalny sposób pasują do modelu programowania obiektowego.

### **Praca ze starszym oprogramowaniem**

Bliższe spojrzenie na oprogramowanie naukowe ujawnia, że komponenty obliczeniowe lub symulacyjne w wielu aplikacjach opierają się na konwencjonalnych systemach plików. Dlatego ścieżka pliku jest powszechnie używana jako parametr wejściowy dla plików wykonywalnych. Podobnie wiele plików skryptów jest zależnych od systemu plików. Potrzebna jest nowa metoda, która może przekształcić interfejs oprogramowania z interfejsu opartego na systemie plików na zgodny z chmurą danych. Wreszcie narzędzia do wizualizacji wymagają obsługi danych z chmury danych. Większość dostawców chmur danych rozwija swoje aplikacje w oparciu o technologię przeglądark

internetowych. Jednak narzędzia do wizualizacji są szeroko stosowane w środowisku naukowym, ponieważ przeglądarki internetowe ogólnego przeznaczenia nie spełniają określonych wymagań, takich jak renderowanie grafiki 3D i obsługa formatów danych naukowych. Aby zapewnić aktywny dostęp do danych przechowywanych w chmurze danych, potrzebne są wydajne mechanizmy interakcji z narzędziami wizualizacji.

### **Dane w czasie rzeczywistym**

Jedną z charakterystycznych cech zarządzania danymi naukowymi jest różnorodność źródeł danych. Nowoczesne czujniki i cyfrowe urządzenia doświadczalne wprowadzają dane bezpośrednio do magazynu danych. Te dane w czasie rzeczywistym często trafiają do magazynu jako dane strumieniowe. Przetwarzanie danych strumieniowych różni się od konwencjonalnego przetwarzania danych wykonywanego w implementacjach chmury danych, takich jak przeszukane strony internetowe lub dane osobowe. Na przykład Unidata (Unidata, 2010) zapewnia kolekcje danych z obserwacyjnych źródeł danych do badań meteorologicznych i prognozowania pogody. Dane satelitarne dostarczane są co godzinę w różnych rozdzielczościach. Każdego dnia z około 4000 samolotów dostarczanych jest około 140 000 obserwacji wiatru i temperatury. Ponadto dane z 152 stacji radarowych NexRed Doppler zbierane są co 5, 6 lub 10 minut. Niektóre z tych danych muszą się ścigać, aby mogły zostać dostarczone do komponentu symulacyjnego w przypadku nagłych zdarzeń pogodowych, takich jak tornado lub huragan. Wydajny dostęp do danych w czasie rzeczywistym umożliwiłby eksplorację danych w czasie rzeczywistym i ostatecznie znacząco poprawiłby ogólną wydajność obliczeń.

### **Programowalne interfejsy do optymalizacji wydajności**

Chmura danych zapewnia skalowalność do zarządzania danymi naukowymi. Skalowalność jest krytycznym wymogiem zarządzania danymi przy stale rosnących ilościach danych. Jednak wiele projektów badań naukowych wymaga również stosunkowo niskich opóźnień, aby spełnić wymagania dotyczące dostępu na żądanie i obliczeń. Google Earth przechowuje wstępnie przetworzone obrazy (około 70 terabajtów) na swoim dysku. Obrazy te są indeksowane w stosunkowo małej tabeli (~500 GB). Ta tabela musi obsługiwać dziesiątki tysięcy zapytań na sekundę na centrum danych z małymi opóźnieniami. Dlatego ta tabela jest hostowana na setkach serwerów tabletów i zawiera rodziny kolumn w pamięci. Jak widać na przykładzie Google Earth, projektowanie dobrze działających systemów danych nie jest trywialne w przypadku implementacji chmury danych. W przeciwieństwie do konwencjonalnych systemów baz danych które zapewniają wbudowaną pamięć podręczną, schemat replikacji lub schematy optymalizacji, implementacje chmury danych wymagają zaangażowania programistów i projektantów systemów w proces optymalizacji wydajności. Potrzebne są programowalne interfejsy do optymalizacji wydajności.

### **Problemy z rozproszoną bazą danych**

Chmury danych mają wiele wspólnych problemów z rozproszonymi systemami baz danych. Obejmuje to odporność na awarie, zarządzanie konfliktami, rozproszoną blokadę i integralność danych. Odporność na awarie ma kluczowe znaczenie dla przetwarzania o dużej przepustowości, które może obejmować przetwarzanie, które może potrwać od kilku dni do kilku tygodni, aby ukończyć zadanie. Integralność danych jest niezbędna do zapewnienia dokładności wyniku. Ponadto w przypadku danych, które są archiwizowane przez długi czas, wymagane jest zapewnienie bezpieczeństwa danych.

### **Bezpieczeństwo i prywatność**

Użytkownicy naukowcy potrzebują bezpieczeństwa i prywatności, aby uzyskać dostęp do swoich produktów danych osobowych. Użytkownicy wymagają bezpiecznego dostępu do danych w celu ich

wykrywania, przeglądania i przetwarzania. Dlatego dane wrażliwe mogą być szyfrowane przed przesłaniem do magazynu w chmurze danych. Aby uniknąć nieautoryzowanego dostępu do danych wrażliwych, żadna aplikacja działająca w chmurze nie powinna mieć możliwości bezpośredniego odszyfrowania danych. Jednak w celu odszyfrowania zestawu danych przenoszenie całego (lub dużej części) zestawu danych w tę i z powrotem z magazynu w chmurze danych jest zadaniem wymagającym dużej przepustowości/mocy obliczeniowej. Tak więc Adabi sugeruje, że system analizy danych, który może działać bezpośrednio na zaszyfrowanych danych znacznie poprawi wydajność.

## **Wnioski**

Przetwarzanie w chmurze oferuje oczywiste korzyści, takie jak kolokacja danych z obliczeniami oraz ekonomia skali w hostingu usług. Chociaż platformy te oczywiście bardzo dobrze sprawdzają się w ich bieżącym zamierzonym zastosowaniu w wyszukiwarkach lub elastycznym hostingu komercyjnych witryn internetowych, ich rola w obliczeniach naukowych wciąż ewoluuje. W niektórych scenariuszach analizy naukowej dane muszą być zbliżone do eksperymentu. W innych przypadkach węzły muszą być ściśle zintegrowane z bardzo małym opóźnieniem, podczas gdy w niektórych przypadkach wymagana jest duża przepustowość we/wy. Istnieje silna tendencja do przenoszenia danych naukowych do chmury. Spodziewamy się, że trend ten będzie się utrzymywał i przyspieszał w przyszłości. W miarę jak coraz więcej systemów zaczyna korzystać z chmury danych, spodziewamy się, że kwestie przedstawione w poprzedniej sekcji będą nabierały coraz większego znaczenia, a także będą obszarem, w którym będzie dużo aktywności badawczej.