

ИНФОРМАЦИОННЫЕ ТЕХНОЛОГИИ

Лекция 5. Грид-технологии и Большие данные

Курс лекций

Что такое грид-вычисления?

Грид-вычисления (от grid – решетка, сеть):

- форма распределенных вычислений, в которой «виртуальный суперкомпьютер» представлен в виде кластеров соединённых с помощью сети, слабосвязанных, гетерогенных компьютеров, серверов, СХД, ЦОД, работающих вместе для выполнения очень большого объема вычислений (заданий, операций, работ).
- географически распределённая инфраструктура, объединяющая множество ресурсов разных типов (процессоры, долговременная и оперативная память, хранилища и базы данных, сети), доступ к которым пользователь может получить из любой точки, независимо от места их расположения.

Преимущество распределённых вычислений - отдельная ячейка вычислительной системы может быть приобретена как обычный неспециализированный компьютер, т.е. вычислительные мощности суперкомпьютера, можно получить с гораздо меньшей стоимостью.

Распределенный характер грид-систем роднит их с распределенными информационными системами.

История и примеры

Обосновали Я.Фостер, К.Киссельман, С.Тики в начале 90-х годов. Их определение: «грид-компьютинг - это **скоординированное** разделение ресурсов и решение задач в динамически меняющихся виртуальных организациях со многими участниками».

Метафора, обозначающая возможность простого доступа к вычислительным ресурсам, как к электрической сети (аналог power grid)

Применяется преимущественно для научных исследований, требующих громадных вычислительных ресурсов.

Примеры:

- большой адронный коллайдер самый большой в мире ускоритель элементарных частиц (85 % всех вычислительных задач сейчас выполняется вне ЦЕРНа);
- проект Fusion - разработка метода получения электроэнергии с помощью термоядерного синтеза на экспериментальном реакторе (ТОКАМАК).

В России: Дубна (ОИЯИ), Москва (НИИЯФ МГУ, ФИАН, ИТЭФ), Протвино (ИФВЭ), Гатчина (ПИЯФ). В единую сеть с этими центрами связаны и центры других стран-участниц ОИЯИ — в Харькове, Минске, Ереване, Софии, Баку, Тбилиси.

Критерии GRID-системы

Отцы-основатели видят 3 критерия. Система называется GRID, если она:

1. координирует использование ресурсов при отсутствии централизованного управления этими ресурсами (если это не так, мы имеем дело с локальной системой управления);
2. использует стандартные, открытые, универсальные протоколы и интерфейсы (если это не так, мы имеем дело со специализированной прикладной системой);
3. нетривиальным (точнее, неаддитивным) образом обеспечивает высококачественное обслуживание (выгода от использования комбинированной системы значительно выше, чем от суммы ее отдельных частей) .

GRID-системы и суперкомпьютер

В обоих случаях используется принцип **распараллеливания вычислений** и имеется **некоторое управляющее ПО**.

В суперкомпьютерах – большое число процессоров объединяется локальной высокоскоростной шиной.

В GRID-системах – вычислительные ресурсы, сконцентрированные в различных ЦОД (серверы со стандартными процессорами, СХД, ИБП и т. д. объединяются через сети (локальные и/или глобальные) при помощи стандартных протоколов.

Грид-системы и облако (grid & cloud)

Я.Фостер: «Облака выросли из грид-вычислений и основываются на концепции инфраструктуры грид. Эволюция подхода заключается в том, что вместо предоставления "сырых" вычислительных ресурсов и ресурсов хранения данных, в облаках обеспечивается предоставление более абстрактных ресурсов в виде сервисов».

Различия

Грид-системы:	Облачные вычисления
<ul style="list-style-type: none">- одна сложная задача распределяется на несколько вычислительных узлов, что обеспечивает высокую загрузку вычислительных ресурсов;	<ul style="list-style-type: none">- нескольких задач выполняются на одном физическом сервере, разделенном на виртуальные машины;
<ul style="list-style-type: none">- используются для исполнения задач за ограниченный промежуток времени;	<ul style="list-style-type: none">- ориентированы на предоставление "долгоживущих" сервисов;
<ul style="list-style-type: none">- ориентированы на решение отдельных научных задач посредством суперкомпьютерных систем;	<ul style="list-style-type: none">- ориентированы на непрерывное предоставление определенных сервисов конечным пользователям;
<ul style="list-style-type: none">- строятся на базе нескольких компаний с четкими правилами взаимодействия и предоставления программно-аппаратных ресурсов;	<ul style="list-style-type: none">- позволяют любой компании использовать сервисы, оплачивая только те ресурсы, которые необходимы для решения ее собственных задач;
<ul style="list-style-type: none">- предоставляют программно-аппаратную базу для развертывания вычислительной инфраструктуры;	<ul style="list-style-type: none">- предоставляют интегрированный подход для всех моделей информационных услуг: IaaS, PaaS, SaaS;
<ul style="list-style-type: none">- интерфейсы ориентированы на взаимодействие посредством специального интерфейса, которым может воспользоваться только профессиональный программист.	<ul style="list-style-type: none">- для каждой модели (IaaS, PaaS, SaaS) предоставляется свой интерфейс, что позволяет удовлетворить потребности, как отдельных пользователей, так и корпоративных клиентов.

Big Data: Новое слово в ИТ?

Большие Данные - серия подходов, инструментов и методов обработки структурированных и неструктурированных данных огромных объёмов и значительного многообразия для получения результатов, доступных для восприятия человека. Этот подход актуален в условиях непрерывного прироста информации, увеличения ее неоднородности и распределенности по узлам вычислительной сети. Данный подход сформировался в конце 2000-х годов, как альтернативных традиционным СУБД и решениями класса бизнес аналитики (BI - Business Intelligence).

Характеризуются тремя большими «V»:

1. **volume** – объем (терабайты - 2^{40} , петабайты - 2^{50} , эксабайты - 2^{60});
2. **velocity** – скорость (и прироста данных, и их обработки, и выдачи по запросу; в идеале – в реальном масштабе времени);



3. **variety** - многообразие (возможность одновременной обработки различных типов структурированных и неструктурированных данных - информации с сенсоров, поисковых систем, социальных сетей, медицинская и финансовая информация, SMS, мультимедиа: фотографии, презентации с графикой, музыкой, аудио и видео).

Есть еще две характеристики «Больших данных» — их ценность (принятие верного решения в нужный момент времени) и возможность работы с ними без предварительной подготовки данных.

История: статья Клиффорда Линча «Как могут повлиять на будущее науки технологии, открывающие возможности работы с большими объёмами данных?» в журнале «Nature» от 03.09.2008г.

Метафоры: аналог «Большой нефти», «Большой руде» и т.д.

По итогам 2011 года - **явление номер два** в информационной инфраструктуре после виртуализации.

Актуальность: в 2013 году объем мировых данных превысил 1,2 зеттабайт (2^{70}), в 2015 ожидалось уже 8 зеттабайт [для справки, есть еще 1 йотабайт = 2^{80}]. Т.е. почти удвоение по закону Мура. Если записать 8 ZB на диски, то это будет примерно 20 стопок высотой от Земли до Луны.

Google - 31 миллиард запросов в месяц, в день обрабатывает более 1 петабайта.

Facebook – 750 миллионов пользователей, 10 млн. загрузок фотографий ежечасно. «Нравится» – 3 млрд. раз в день.

Twitter – 400 млн. обращений в день в 2012г. С увеличением в год на 200%.

Области применения

- военные применения (космическая и аэроразведка, мониторинг ситуации)
- научные исследования (мониторинг среды, зондирование атмосферы, расшифровка генома человека);
- медицина (обследование организма в целом, анализ аномалий генов конкретного человека, статистика);
- коммерция (анализ влияния большого числа факторов на объемы продаж большого числа товаров).

Основные тренды развития

1. Сложность данных (данные могут быть как структурированными, так и неструктурированными).
2. Сложность анализа (могут анализироваться одновременно изображения, видео, тексты, производится распознавание образов т. д.).
3. Растущие требования к бизнес аналитике (прогнозирование в реальном масштабе времени).
4. Меняющаяся экономика вычислений (облачные вычисления снижают стоимость хранения и обработки данных).
5. Легкость и дешевизна распараллеливания обработки.

Особенности работы с Большими Данными

1. Анализируются все данные, а не статистические выборки

Для определения зоны распространения гриппа N1H1 специалисты Google выявили 45 из 50 миллионов условий поиска определенных лекарств и сравнил их с зонами распределения гриппа за 2003-2008 годы. Точность определения территорий распространения заболевания составила 97%.

Стив Джобс продлил себе жизнь на несколько лет проанализировав свою ДНК **полностью**, что позволило врачам менять лекарства при мутациях его раковой опухоли.

Компания Хоом, специализирующаяся на денежных переводах, проанализировав **все** данные по операциям с кредитными картами, обнаружила действия преступной группировки.

Анализ результатов **всех** боев в борьбе сумо позволил выявить наиболее вероятные договорные бои.

2. Отсутствие точности

В мире БД высокая точность невозможна – данные постоянно меняются, неупорядочены, разного качества, разбросаны по разным серверам иногда по всему миру.

Переводы Google охватывали миллионы страниц переводимых документов различного качества, взятых из интернет-контента. Система содержала триллион слов в 95 миллиардах англоязычных предложений сомнительного качества. К середине 2012 года служба охватила более 60 языков и способна принимать голосовой ввод с 14 языков для моментального перевода.

Индекс потребительских цен – опрос по ценам на 23 000 товаров в 90 городах США. Сканирование Web-страниц позволяет учесть стоимость 5 млн. товаров, хотя точность сведений гораздо ниже, чем при опросах.

Отсутствие жесткого структурирования записей в базах данных.

3. Корреляция, а не причинность

Отход от поиска причинностей: вместо причинностей – корреляции. Если мы знаем, что сочетание двух веществ излечивает определенную болезнь, то нам не так важно, почему это происходит.

Amazon - предложение книг не по тому, что покупал данный человек ранее, а по схожести самих книг, т.е. по корреляции содержания.

Walmart – повышенный спрос на тосты Pop-Tarts в период приближения стихийных бедствий.

Российские особенности

- основные потребители – банковский сектор (работа с клиентскими базами) и телеком (анализ абонентской базы);
- перспективны госсектор (электронное правительство) и медицина (быстрый анализ общего состояния пациента);
- ИТ-компании типа Google и Amazon, держатели больших объемов данных, пока отсутствуют, но перспективны «Яндекс», «Mail.ru»;
- научно-исследовательские организации могли бы использовать, но бюджеты маловаты;
- МСБ не имеет бюджетов для работы с БД;
- исследовательские центры ЕМС в Санкт-Петербурге и Сколково (биомедицина и энергоэффективность).