

Was versteht man unter Big Data, wer braucht es und wie unterscheidet es sich vom klassischen Data Warehousing & BI? Zudem stellt sich die Frage, ob große Datenmengen heutzutage nicht auch in den modernen Data-Warehouse-Appliances gut aufgehoben sind. Der Artikel beantwortet diese Fragen und betrachtet typische Problemstellungen für Hardware, Software und Datenmodellierung jeweils mit einem Blick auf die Lösungsansätze von Oracle Exadata, Teradata & Co.

Big Data (Warehouse?)

Peter Welker, Trivadis GmbH, Stuttgart

Keine IT-Veranstaltung oder BI-Publikation ohne „Big Data“! Auf der DOAG 2012 BI gab es einen eigenen Track für dieses Thema und auf der TDWI Konferenz 2012 im Juni fanden sich sieben Vorträge dazu – nicht gerechnet die Präsentationen, die dieses Thema zumindest streiften. Nach Gartner ist der Hype gerade erst angelaufen. Aber was ist eigentlich die Ursache für diese Welle? Das Datenvolumen in IT-Systemen steigt doch schon seit Jahrzehnten kontinuierlich an.

Geschätzte 1,8 Zettabyte (entspricht 1.800 Exabyte) an Daten wurden im Jahr 2011 weltweit erzeugt und repliziert – dazu gehört auch die Verbreitung im Internet. Das ist neunmal so viel wie noch vor fünf Jahren [1]. Würde man die für die Speicherung dieser Daten benötigten Server-Festplatten hochkant nebeneinander stellen, reichte dieser Gürtel zweimal um die Erde. Wirklich neu produziert und mehr oder weniger dauerhaft gespeichert wurden 2010 geschätzte 13 Exabyte Daten. Das McKinsey Global Institute (MGI) sieht in der Nutzung der in diesen Daten enthaltenen Informationen ein jährliches Potenzial von rund 300 Milliarden Dollar allein im amerikanischen Gesundheitswesen und 250 Milliarden Euro in Europas öffentlichem Sektor [2].

Die beeindruckenden Zahlen wecken möglicherweise die Sorge, gerade etwas Wesentliches zu verpassen. Dieser Quantensprung an Quantität darf aber nicht darüber hinwegtäuschen, dass auch heute nur ein winziger Bruchteil dieser Informationen für die Entscheidungsfindung in modernen Unternehmen relevant sind.

Un-/Poly-/Semi-/Irgendwie strukturierte Daten

Ein immer größerer Anteil dieser neuen Daten basiert aus BI-Sicht auf weitgehend unstrukturierten, aber immens umfangreichen Formaten wie Bildern, Audios, Videos oder Layouts. Auf YouTube wurde im Frühjahr 2010 jede Minute vierundzwanzig Stunden Videomaterial hochgeladen, heute sind es mehr als fünfzig. Daneben steigt auch der Platzbedarf innerhalb desselben Mediums drastisch. Ein Full-HD-Video mit zeitgemäßer Tonspur benötigt mit bis zu 6,75 Megabyte pro Sekunde leicht dreißigmal so viel Speicherplatz wie derselbe Film im früheren PAL-Fernsehen, transportiert aber für den überwiegenden Teil aller denkbaren Anwendungsfälle immer noch dieselben Informationen. Und mit „4K2K“ und „8K4K“ stehen bereits die Nachfolger mit vier- beziehungsweise sechzehnfacher Auflösung in den Startlöchern. Abgesehen von wenigen strukturierten Anteilen (Tags) sind solche Daten für die Unternehmenssteuerung eher irrelevant. Das mag sich gegebenenfalls durch Anwendungen wie „automatisierte Gesichtserkennung“ in Zukunft partiell ändern, wird sich aber selbst dann wohl meist in der Aggregation dieser Daten in kleinen, klar strukturierten Einheiten niederschlagen.

Interessant ist das Potenzial für einheitlich strukturierte Daten wie den personifizierbaren, durch Volltext und Multimedia angereicherten „Social-Media Content“ aus Facebook, Twitter & Co. Dieser ist zwar mit klassischen BI-Ansätzen (noch) nicht leicht zu analysieren, bietet aber bereits heute

die Möglichkeit, Meinungsführer und Trends zu identifizieren und wird auch schon vereinzelt im Marketing genutzt. Hier sind zur Analyse von Beziehungen sogenannte „Graphen-Datenbanken“ nützlich.

Besonderes Augenmerk benötigen auch die Informationen, die sich inzwischen mehr und mehr durch permanent von Maschinen produzierte oder produzierbare Daten ergeben. Man spricht auch medienwirksam vom „Internet of Things“. Dazu darf man sowohl geografisch-persönliche Ereignisse wie die Lokalisierung von Smartphones und das Lesen von RFIDs, aber auch die heute fast schon klassischen Web-Logs oder die immer mitteilungsüchtigere Produktions-Sensorik zählen.

Strukturierte Daten

Natürlich spielen auch herkömmliche Daten eine bedeutende Rolle im Mengenwachstum. Unternehmen und Behörden erzeugen heute deutlich größere Informations-Einheiten, speichern also immer mehr Informationen zu jedem Kunden und mehr Details zu jeder Transaktion. Gleichzeitig wachsen auch die Anzahl der Informations-Einheiten und damit die Granularität in Stammdaten und Bewegungsdaten gleichermaßen. Diese Daten bilden nach wie vor den Kern der traditionellen BI – und sind nicht selten über bestimmte Zeiträume hinweg zur Gewährleistung höchster Transparenz erforderlich, wie zum Beispiel Diagnose- und Leistungsdaten im Gesundheitswesen, Call Data Records bei den Telekommunikations-Dienstleistern oder Kontenbewegungen im Finanz-

wesen. Gerade durch das Zusammenführen dieser Informationen zu einem einheitlichen Kundenverständnis entstehen wertvolle zusätzliche Erkenntnisse.

Das Dilemma

Es stellt sich die Frage, wie mit dem Dilemma des Datensammlers umgegangen werden kann: „Müssen alle Daten über lange Zeit gesammelt werden, um schon heute für zukünftige Anforderungen gerüstet zu sein? Oder genügt es, diese neuen Datenquellen erst anzuzapfen, sobald konkrete Anforderungen aufkommen?“ Letzteres erlaubt deutlich geringere Investitionen, allerdings auf Kosten des Risikos, von neuen Erkenntnissen nicht schnell genug profitieren zu können und auf deren Geschichte zu verzichten.

Big Data, eine disruptive Technologie?

Die große Riege der NoSQL-, BigTable-Clone- und sonstigen verteilten Datenbanken – also Hadoop, Dynamo, Cassandra & Co. – haben ihre Einsatzfähigkeit für (uneinheitlich) strukturierte Daten in Einzelfällen längst eindrucksvoll unter Beweis gestellt. So betreibt beispielsweise Yahoo Hadoop-Cluster mit mehreren Hundert Petabyte Daten.

Es stellt sich demnach die Frage nach der richtigen Technologie: „Bin ich mit meinen gegenwärtigen BI-Lösungen auf dem Holzweg? Wird „Big Data“ die Art und Weise, wie wir mit unseren entscheidungsrelevanten Daten umgehen, von Grund auf verändern?“

Heute deutet alles darauf hin, dass die gängigen Big-Data-Ansätze mit Hadoop & Co. mittelfristig nicht geeignet sind, die Aufgaben klassischer BI-Lösungen zu übernehmen. Warum? Die Nutzung von Hadoop mittels Map-Reduce-Framework ist zwar prinzipiell extrem flexibel – schließlich kann man alles tun, was mit Programmierung und Dateien umsetzbar ist –, dadurch aber auch mit sehr hohem Entwicklungsaufwand verbunden und direkt für Endanwender praktisch nicht nutzbar. Alternative Datenzugänge wie Hive, das eine SQL-Schnittstelle für Hadoop darstellt und Map-Reduce-Zugriffe generiert, sind hingegen weit von der

Funktionalität klassischer Datenbank-Systeme entfernt.

Letztlich ist der Anspruch der BI an Antwortzeiten (etwa Sub-Second bei MOLAP-Abfragen), Variabilität, Einfachheit für Entwickler und Anwender sowie die Ausrichtung auf seit fast zwanzig Jahren etablierte Methoden wie Pivotisierung und dimensionale Modelle im Zusammenspiel mit relationaler und multidimensionaler OLAP-Technologie sehr ausgeprägt. Langfristig könnten die BI-Anwenderwerkzeuge Datenquellen wie Hadoop & Co. als Alternativen einbeziehen. Solange lassen sich mit Big-Data-Ansätzen aber eher gänzlich neue Aufgabenfelder erschließen oder zweckentfremdende Prozesse aus bestehenden Data Warehouses extrahieren. Besonders kann jedoch die Vor- und Aufbereitung entscheidungsrelevanter Informationen aus bisher unzugänglichen Daten den etablierten BI-Systemen schon heute gute Dienste leisten. Die neuen Technologien sind also nicht disruptiv, sondern vielmehr ergänzend und als Quelle innerhalb der Business Intelligence nutzbar.

Lösungsansatz „Smart Data“

Ein naheliegender, praktikabler Kompromiss stellt diese Strategie dar. Dabei können die hohen Anforderungen an die Analyse strukturierter Daten heute mit DWH-Appliances bis in den zwei- und dreistelligen Terabyte-

Bereich hinein bewältigt werden – allerdings zu entsprechenden Kosten. Die große Masse der uneinheitlich strukturierten Daten wird dazu mit den jeweiligen Lösungen aus dem „NoSQL & BigTable“-Umfeld (wie Hadoop) verwaltet, selektiert und in bestimmtem Umfang auch analysiert. Bei Bedarf können die dort gehaltenen Daten dann aufbereitet und ins klassische DWH geladen werden. Aus Big Data würde somit für BI-relevante Anwendungsfälle „Smart Data“ (siehe Abbildung 1).

BigData und DWH-Appliances

Inzwischen stellen einige Anbieter zwei verschiedene Varianten von Appliances zur Auswahl: Big-Data-Lösungen und „Massive Parallel Processing (MPP)“-Data-Warehouse-Cluster-Lösungen. Die für „Big Data“ deklarierten Lösungen wie Oracle Big Data Appliance oder EMC Greenplum HD bauen weitgehend auf Hadoop auf und stellen dafür spezielle Hadoop-Distributionen mit zahlreichen Erweiterungen und eigenen Implementierungen beispielsweise von Key-Value-Stores (TeraData Aster) zur Verfügung.

Im zweiten Teil des Artikels konzentrieren wir uns auf diese Data-Warehouse-Appliances und betrachten, welche Lösungen hier angeboten werden und welche Architekturen dafür zum Einsatz kommen. Typische Ver-




Abbildung 1: Mehrstufiges Konzept zur Analyse von Daten unterschiedlichen Strukturierungsgrades

treter dieses Genres sind Oracle Exadata, Teradata, IBM Netezza, HP Vertica, EMC Greenplum, Microsoft PDW oder Exasol.

Diese Data-Warehouse-Appliances fokussieren sich auf klassische DWH-Methoden und nutzen dafür spezielle RDBMS-Implementierungen mit weitgehend standardisierter SQL-Schnittstelle. Das Besondere daran: Es handelt sich um Datenbank-Cluster, die nach dem Scale-Out-Prinzip große Datenmengen auf einzelne, relativ kleine Server-Knoten verteilen. Durch geschickte Partitionierung der Aufgaben werden die Daten dann möglichst direkt auf den einzelnen Knoten vorverarbeitet, also beispielsweise gefiltert, per Join miteinander verknüpft und aggregiert. Abschließend werden die stark verkleinerten Resultate an einer Stelle zusammengeführt und dem Anwender zurückgegeben. Dafür müssen nur relativ kleine Ergebnismengen über das interne Cluster-Netzwerk geschickt werden.

Generelle Aufgabenstellungen bei großen Datenmengen

Prinzipiell sind die Aufgabenstellungen an Skalierung durch Verteilung bei allen Cluster-Lösungen, ganz gleich ob HDFS oder Datenbank-Cluster, sehr ähnlich. Es geht dabei vereinfacht gesagt um Folgendes:

- Eine einzelne Aufgabe auf vorhandene Ressourcen zu verteilen (Partitionierung)
- Diese Verteilung möglichst gleichmäßig durchzuführen (Skewing vermeiden)
- Auch bei mehrstufigen Aufgaben verfügbare Ressourcen immer optimal auszulasten (Pipelining)
- Dabei möglichst viele Operationen innerhalb eines Knotens auszuführen (Lokalität)

Dabei gibt es natürlich jede Menge Möglichkeiten, die Auslastung der Ressourcen gering zu halten beziehungsweise optimal aufeinander abzustimmen, um gute Antwortzeiten zu erreichen wie:

- Organisation (Spalte/Zeile) und Kompression der Daten, um einen

höheren De-Facto-Durchsatz zu erzielen

- Maßnahmen zur Reduktion der zu verarbeitenden Daten wie Indexierung, horizontale und vertikale Partitionierung, Vorhalten von Min-/Max-Werten für Datenbereiche etc.
- Priorisierung bestimmter Abfragen nach Anwendergruppe oder zu erwartender Laufzeit (Ressourcen-Management) etc.

Da analytische Aufgaben meist eine ganze Reihe von elementaren Operationen beinhalten (Scans, Joins, Filter, Gruppierungen, Sortierungen), kommt es auch und besonders darauf an, wie der Query-Optimizer eine Aufgabe zerlegt, wie er also die einzelnen Schritte zur Erfüllung der Aufgabe auswählt und kombiniert. Soll er beim Join die Daten einer Tabelle an alle Knoten schicken oder nur Teile davon an bestimmte Knoten? Soll er zuerst die Tabelle A oder die Tabelle B scannen? Um diese und noch viel mehr Fragen beantworten zu können, muss bekannt sein:

- Nach welchen Kriterien die Daten auf den Knoten verteilt werden (Distribution)
- Welche Tabelle welche Datenmengen hat und welche Daten sich in den einzelnen Spalten befinden (Statistiken)

Beispiele für Lösungsansätze

Generell sind die Anbieter mit ihren Lösungen auf die Anforderungen eingestellt. Alle nutzen umfangreiche Statistiken über die Datenverteilung für die Ermittlung von Ausführungsplänen und bieten Lösungen zur Reduktion des Datenverkehrs über den Interconnect. Zur Verteilung/Distribution der Daten auf die einzelnen Knoten teilen sich die Lösungen in zwei Lager: Die einen nutzen eine klassische Shared-Nothing-Architektur, haben also pro Knoten lokale Platten und verteilen die Daten einer Tabelle zufällig oder nach dem Hashwert von definierbaren Spalten möglichst gleichmäßig auf die Knoten. Die anderen – eigentlich nur Oracle Exadata – fahren einen gemischten Ansatz. Dabei kommen

zwei Typen von Knoten zum Einsatz: Die einen (klassische Datenbank-Knoten, meist als RAC konfiguriert) sehen die anderen (Storage Server) als eine Art „Shared Disks“. Auf den Storage-Servern wiederum werden die Daten dann jedoch gleichmäßig verteilt. Dieser eher hybride Ansatz erlaubt Oracle die „1:1“-Nutzung seiner Standard-Funktionalität. Natürlich speichern alle Anbieter standardmäßig alle Daten redundant auf mehreren Knoten, um Ausfallsicherheit zu gewährleisten.

Alle erlauben auch die Kompression von Daten. Die Methoden dafür sind allerdings sehr unterschiedlich. Oracle Exadata, EMC Greenplum und mittlerweile auch Teradata bieten beispielsweise verschiedene Varianten (zeilenorientiert, spaltenorientiert) in verschiedenen Stärken an. Die rein spaltenorientierten Lösungen wie HP Vertica und Exasol komprimieren natürlich rein spaltenorientiert, was je nach Datenlage sehr effizient sein kann, und tun dies „out of the box“. IBM Netezza hingegen nutzt spezielle Hardware (FPGAs), um beispielsweise die Kompression auf Disk möglichst effektiv zu gestalten.

Beim Ressourcen-Management können nur wenige Anbieter direkt Einfluss auf die einzelnen Elemente einer Operation nehmen, also CPU, Disk und Netzwerk prozentual auf einzelne Aufgaben verteilen, um so beispielsweise taktischen Anwendern eine garantierte Verfügbarkeit zu gewährleisten. Teradata hat hier sehr umfangreiche Möglichkeiten und Oracle Exadata bietet – im Gegensatz zur normalen Datenbank – neben der prozentualen CPU-Zuteilung auch eine prozentuale IO-Zuteilung an. Bei den meisten anderen Lösungen beschränken sich die Möglichkeiten auf die Nutzung von unterschiedlichen Queues pro Anwendergruppe oder auf vergleichbare Ansätze.

Standby, Backup & Co.

Was bedeutet die Einführung einer solchen Lösung nun aber aus systemadministrativer Sicht?

Backups kann man natürlich bei allen Systemen ganz klassisch (auch im Betrieb) ziehen. Aber ein Snapshot, wie

man ihn aus der SAN-Welt kennt, ist bei lokalen Disks nicht möglich. Eine Datenbank zu klonen bedeutet also schlicht, sie zu kopieren.

Bei den Hochverfügbarkeits-Lösungen (HA) wird es uneinheitlich. Manche erlauben, den Cluster auseinanderzuziehen (Stretch-Cluster). Das ist zwar bei relativ kleinen Abständen (etwa 100 m über eine Feuerschutzwand) noch performant möglich, bedingt aber auch eine Verdopplung der Redundanz, wenn nach dem Ausfall einer Seite die andere alleine nicht ohne Redundanz der Disks weiterlaufen soll. Wenn die Anforderungen allerdings eine Verteilung auf weit entfernte Standorte nötig machen (etwa 100 km), kann ein Stretch-Cluster auch sehr ineffizient werden, denn einerseits steigt mit der Entfernung naturgemäß die Latenz und andererseits sind optimierte Interconnects in WANs nicht mehr so ohne Weiteres realisierbar.

Oracle bietet immer die Möglichkeit, eine Standby-Datenbank aufzubauen (Data Guard). Teilweise ist bei anderen Anbietern eine ähnliche Lösung vorhanden oder der Einsatz von Replikationssoftware möglich. Schlimmstenfalls muss man jedoch alle ETL-Prozesse an zwei Standorten laufen lassen.

Kraft versus Intelligenz

Neben den ganzen brachialen Möglichkeiten der Skalierung und der optimalen Ressourcen-Nutzung darf man aber auch die „Intelligenz“ einer Lösung nicht vernachlässigen. So ist es beispielsweise schlicht Geldverschwendung, wenn man in einer typischen DWH-Lösung seine Daten ausschließlich auf dem untersten Granularitäts-Level analysiert, obwohl eine redundante Haltung vor-aggregierter Daten 80 Prozent der Abfragen mit einem Tausendstel des Aufwands bedienen könnte.

Literaturverzeichnis

- [1] IDC Reportserie: „Digital Universe“, 2007 ff. Sponsored by EMC
- [2] MGI Report: „Big Data. The next frontier for innovation, competition, and productivity.“ 2011
- [3] http://static.googleusercontent.com/external_content/untrusted_dlcp/research.google.com/de//archive/mapreduce-os-di04.pdf

Peter Welker
peter.welker@trivadis.com



MuniQSoft GmbH – Datenbanken mit iQ

IT-Consulting	Schulungen	Software-Lösungen	Oracle Lizenzen
<ul style="list-style-type: none"> › Performance Tuning <ul style="list-style-type: none"> • Oracle Datenbank Tuning • Oracle SQL + PL/SQL Tuning › Real Application Clusters › Data Guard + Fail Safe › Datenbank Management <ul style="list-style-type: none"> • Konfiguration • Backup & Recovery • Migration und Upgrade › OEM Grid Control › Oracle Security › Services <ul style="list-style-type: none"> • Remote DBA Services • Telefon-/Remotesupport <p style="font-size: small; margin-top: 10px;">Nutzen Sie unsere Kompetenz für Ihre Oracle Datenbanken.</p>	<ul style="list-style-type: none"> › Oracle SQL › Oracle PL/SQL › Oracle DBA › Oracle APEX › Backup & Recovery › RMAN › Neuerungen 10g/11g › Datenbank Tuning › Datenbank Monitoring › Datenbank Security Wir bieten Ihnen öffentliche Kurse sowie Inhouse-Schulungen. 	<ul style="list-style-type: none"> › Individualsoftware <ul style="list-style-type: none"> • .NET und Visual Basic • Java › Oracle APEX › PL/SQL Unser Ziel: Individuelle Softwareentwicklung mit Fokus auf Ihre Zufriedenheit. 	<ul style="list-style-type: none"> › Oracle Datenbanken <ul style="list-style-type: none"> • Standard Edition One • Standard Edition • Enterprise Edition • Personal Edition › Oracle Produkte <ul style="list-style-type: none"> • Enterprise Manager • Oracle Tools Optimale Lizenzierung durch individuelle Beratung.

MuniQSoft GmbH • Grünwalder Weg 13a • 82008 Unterhaching • Telefon: 089 / 6228 6789-0 • <http://www.muniqsoft.de> • info@muniqsoft.de