Datenbanken: Self-Driving

Stefan Halfpap, Ralf Teusner, Werner Sinzig, Michael Perscheid

29. Juni 2020

Vorlesungsinhalte/-aufbau

- Einführung zu Unternehmensanwendungen
- Grundlagen des IT-gestützten Rechnungswesens und der Planung
- Einführung zu relationalen Datenbanken und Anfrageverarbeitung
- Grundlagen von (spaltenorientierten) Hauptspeicherdatenbanken
- **Trends in Hauptspeicherdatenbanken**
- Klausur

Überblick

- Motivation - Datenbankadministration
  - Warum wird Administration benötigt
  - Status quo
  - Quo vadis
- Self-Driving
  - Idee
  - Grenzen bisheriger Ansätze
  - Definition
  - Herausforderungen
- Zusammenfassung

Literatur und Empfehlung

- Basiert in großen Teilen auf der Arbeit von Jan Koßmann

  https://hpi.de/plattner/people/phd-students/jan-kossmann.html

- Andy Pavlo
  - „Advanced Database Systems“ – Self-Driving Databases

    https://15721.courses.cs.cmu.edu/spring2019/slides/25-selfdriving.pdf
  - Andy Pavlo „Make your Database Dream of Electric Sheep“ (Talk)

    http://www.cs.cmu.edu/~pavlo/slides/selfdriving-sfo2018.pdf

Self-Driving Datenbanksysteme
Motivation – Warum brauchen DBs einen Administrator?

- Datenbanken sind vielseitig einsetzbar
  - Nicht angepasst auf spezifische Anwendungsfälle
  - Aber optimale Performanz und Kosteneffizienz sind wünschenswert
- Datenbanken sind komplexe Systeme
  - Komplexe Workloads und Daten
  - Viele Konfigurations- und Optimierungsmöglichkeiten
    - "Every time database vendors don't know how to do it, they introduce a new knob" Goetz Graefe
    - Physische Datenorganisation, z.B. Indexauswahl
  - (Zunehmend) heterogene Hardware ermöglicht Optimierungen
  - Viele komplexe, teilweise abhängige Komponenten, z.B. Queryoptimierung, Datenkompression

Optimale Konfigurationen hängen von Workload, Daten, Hardware, DBS-Version ab

Self-Driving Datenbanksysteme
Motivation – DB-Administration: Status Quo

- Viele verschiedenartige Konfigurations- und Optimierungsmöglichkeiten
  - Physische Ressourcen z.B. #Servers, #CPUs, Speichergrößen
  - Physische Datenorganisation z.B. Datenlayout, Hilfsstrukturen, Partitionierung, Replikation
  - Datenbanksettings (knobs) z.B. Threadanzahl, Puffergrößen, Mergezyklus

- Datenbankadministratoren konfigurieren und optimieren DB-Systeme oft manuell
  - Anspruchsvolle und zeitaufwendige Aufgabe
  - DB-Administration ist großer Teil der DB-TCO (Total Cost of Ownership)
  - Größe und Komplexität der DBS-Installation hat menschliche Fähigkeiten überschritten

Self-Driving Datenbanksysteme
Motivation – Steigende Komplexität der DB-Administration

- Komplexe, schwankende Mixed Workloads
  - OLTP & OLAP auf der gleichen Datenbank
  - Saisonale (z.B. Quartalsabschluss, Mahnwesen) und unvorhersehbare (z.B. Hypes oder Krisen) Trends

- Steigende Anzahl der Einstellungsmöglichkeiten und DB-Features (z.B. neuer Indextyp)

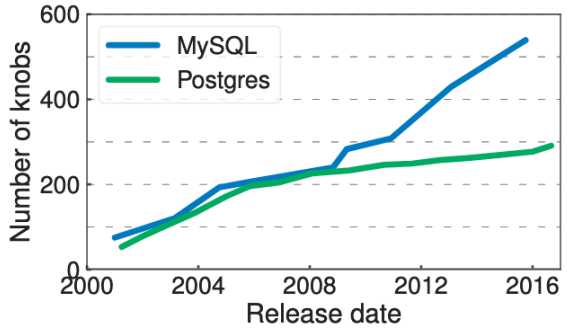

https://db.cs.cmu.edu/papers/2017/tuning-sigmod2017.pdf

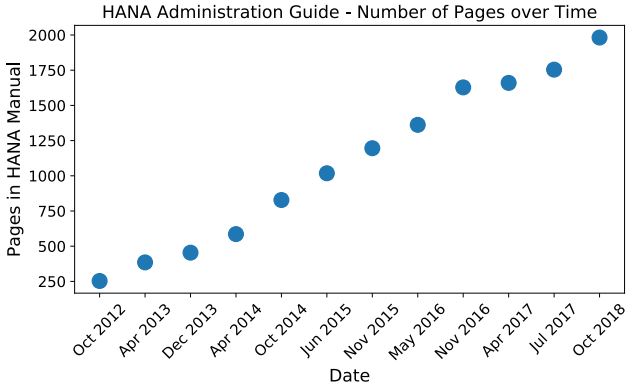

[unveröffentlicht, Jan Koßmann]

Self-Driving Datenbanksysteme
Motivation – Cloudcomputing als zusätzlicher Treiber

- Übergang von On-Premise (vor Ort installiert) zu (On-Demand) Cloudcomputing
- Kosteneffizienz wichtige Eigenschaft fürs Cloud-Geschäft
  - Kunden können Kosten durch „Pay as you go"-Modelle sparen
  - Anbieter können Kosten durch Tuning der gehosteten Systeme sparen (aber begrenztes Wissen zu Workloads und Daten (privacy))

Self-Driving Datenbanksysteme
Idee

Selbstverwaltung und –optimierung des Datenbanksystems (ohne menschliche Interaktion)

- Datenbanksysteme haben Informationen über Workloads, Daten (inklusive Statistiken) und aktuelle Konfiguration
- Verwende Heuristiken, Machine Learning oder andere Optimierungstechniken um optimale/gute Datenbankkonfigurationen zu finden und anzuwenden

Self-Driving Datenbanksysteme
Bisherige Ansätze

- Forschung an automatischer Optimierung des Datenbankdesign begann in den 1970er Jahren
  z.B. Hammer and Chan: „Index Selection in a Self-Adaptive Data Base Management System“ (1976)
- Fokus auf physische Datenorganisation
  - Indexauswahl
  - Partitionierung
  - Datenplatzierung

- Hier: Beispiele für Indexauswahl und Datenplatzierung

Self-Driving Datenbanksysteme
Bisherige Ansätze – Beispiel Indexauswahl

Chaudhuri and Narasayya: "An Efficient, Cost-Driven Index Selection Tool for Microsoft SQL Server" (1997)
http://www.vldb.org/conf/1997/P146.PDF

- Teil des AutoAdmin-Projekts: https://www.microsoft.com/en-us/research/project/autoadmin/
- Indexauswahlalgorithmus mit enger Kopplung an den Optimierer (, der später entscheidet, ob und welcher Index verwendet wird)
  - Daten- und anfragebasierter Ansatz
  - Indexkandidatenauswahl pro Query
  - Dann optimale Kombinationen (nicht skalierbar) und/oder Greedy Heuristik
  - Mehrattributindizes werden unterstützt
  - Verwendet „What-if-index-exists"-Aufrufe
    - Indexerstellung dauert und benötigt Speicherplatz
    - Idee: Schätze Kosten von Indizes – „was wären die Anfragekosten, wenn der Index existieren würde" https://github.com/HypoPG/hypopg

Self-Driving Datenbanksysteme
Bisherige Ansätze – Beispiel Datenplatzierung

Rabl and Jacobsen: "Query Centric Partitioning and Allocation for Partially Replicated Database Systems" (2017)
https://www.redaktion.tu-berlin.de/fileadmin/fg131/Publikation/Papers/allocationCRC.pdf

Halfpap and Schlosser: "Workload-Driven Fragment Allocation for Partially Replicated Databases Using Linear Programming" (2019)
https://www.redaktion.tu-berlin.de/fileadmin/fg131/Publikation/Papers/allocationCRC.pdf

- Datenplatzierung für partielle Replikation
  - Daten- und anfragebasierter Ansatz
  - Optimale Lösung (nicht skalierbar), Greedy Heuristik und Divide-and-Conquer Heuristik
  - Optionen:
    - Robustheit gegen Ausfälle
    - Flexibilität gegen Workloadänderungen

Self-Driving Datenbanksysteme
(Häufige) Grenzen bisheriger Ansätze

https://15721.courses.cs.cmu.edu/spring2019/slides/25-selfdriving.pdf

- Problem 1: **Benötigen menschliche Entscheidungen**

  Mensch muss Zusatzinformation (z.B. Constraints oder Optimierungsziele) bereitstellen oder endgültige Entscheidung treffen, ob Empfehlungen angewendet werden

- Problem 2: **Reaktionäre Maßnahmen**
  Maßnahmen beruhen (häufig) auf vergangenen Beobachtungen, antizipieren aber keine/selten zukünftige Trends/Probleme

- Problem 3: **Keine Integration**
  DB-Komponenten und –Instanzen werden separat optimiert

Self-Driving Datenbanksysteme

Grenzen bisheriger Systeme – Automatisierungslevel basierend auf SAE J3016

https://15721.courses.cs.cmu.edu/spring2019/slides/25-selfdriving.pdf

- Level 1: **Manuell**: System macht nur, was Mensch einstellt; System gibt höchstens Warnungen
- Level 2: **Assistenz**: System gibt Vorschläge; der Mensch fragt und entscheidet
- Level 3: **Teilautomatisierung**: System und Mensch arbeiten gemeinsam am Systemmanagement; der Mensch leitet den Prozess
- Level 4: **Lokale Automatisierung/Optimierung**: Komponenten passen sich selbst an; aber keine Koordination/Integration
- Level 5: **Hochautomatisierung**: Mensch geben grobe Vorgaben/Hinweise; das System erkennt, wenn der Mensch eingreifen sollte
- Level 6: **Self-Driving/Vollautomatisierung**: Keine menschlichen Eingriffe

- Aufgaben:
  - Installation/Deployment
  - Konfiguration
  - Optimierung
- **Ohne** irgendeine **menschliche Interaktion**
  - Maßnahmen bestimmen
  - Zeitpunkt bestimmen
  - Von Maßnahmen für zukünftige Entscheidungen lernen
- **Ganzheitliche Optimierung** des Datenbanksystem (und nicht nur einzelne Komponenten)
- **Proaktiv** (und nicht nur reaktiv)

Self-Driving Datenbanksysteme
Herausforderungen

- Vorhersage von zukünftigen unbekannten (probabilistischen) Workloads

- Komplexes Optimierungsproblem
  - Beeinflussung einzelner Optimierungsoptionen/-einstellungen → **komplexes Modell**
  - (Potenziell) Speicherintensiver, schwierig messbarer, ungenauer **Modellinput**
  - Verschiedene (teils mathematisch komplexe) **Optimierungsansätze/-techniken**
  - Verschiedene (teils widersprüchliche) Ziele (Kosten, Durchsatz, Latenz, Robustheit, Flexibilität für unbekannte Workloads und Daten)

- Integration in die Datenbanksystemarchitektur

Self-Driving Datenbanksysteme
(Eine Auswahl von aktuellen) Forschungsprojekte(n)

- Jan Koßmann: Self-Driving Hyrise

  https://hpi.de/plattner/people/phd-students/jan-kossmann.html

- Carnegie Mellon University – Datenbankgruppe
  - OtterTune – Tuning-as-a-Service für z.B. PostgreSQL, MySQL, ...

    https://db.cs.cmu.edu/papers/2017/p1009-van-aken.pdf
  - Self-Driving Database Peloton und Terrier

    http://www.cs.cmu.edu/~pavlo/papers/p42-pavlo-cidr17.pdf

    https://github.com/cmu-db/terrier

- Tim Kraska et al.: SageDB

  http://cidrdb.org/cidr2019/papers/p117-kraska-cidr19.pdf

Zusammenfassung

- Datenbankadministration ist zunehmend komplexe Aufgabe und wichtig für Cloudcomputing
- Idee von Self-Driving: Datenbankmanagementsystem installiert, konfiguriert und optimiert sich selbst und proaktiv ohne jegliche menschliche Interaktion
- „True autonomous DBMSs are achievable in the next decade."

  Andy Pavlo: Self-Driving Database Management Systems https://15721.courses.cs.cmu.edu/spring2019/slides/25-selfdriving.pdf