

Proseminar Algorithms and Data Structures

Einführungsveranstaltung Wintersemester 2018/19; 10. Oktober 2018

Thomas Noll et al.

Software Modeling and Verification Group
RWTH Aachen University

http://moves.rwth-aachen.de/teaching/ws-1819/algds/





Übersicht

Einführung

Termine

Algorithmen

Datenstrukturen

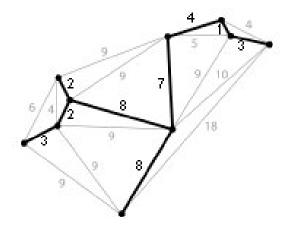


Seminarthema

Thema des Proseminars

Weiterführung und Vertiefung diverser Themen der Vorlesung *Datenstrukturen und Algorithmen*

- Algorithmen:
 - neue Algorithmen
 - andere Komplexitätsmaße, ...
- Datenstrukturen:
 - Bäume
 - Hashing, ...
- Inhalt:
 - Problemstellung
 - Arbeitsweise des Algorithmus bzw. der Datenstruktur
 - Effizienzeigenschaften
 - Anwendungen







Zielsetzung

Ziele des Proseminars

- Selbstständiges Einarbeiten in ein neues Thema
- Literaturrecherche
- Darstellen des Inhalts in einer wissenschaftlichen Ausarbeitung
- Verständliches Präsentieren





Zielsetzung

Ziele des Proseminars

- Selbstständiges Einarbeiten in ein neues Thema
- Literaturrecherche
- Darstellen des Inhalts in einer wissenschaftlichen Ausarbeitung
- Verständliches Präsentieren

Bearbeitung in Zweiergruppen

- Gemeinsame Anfertigung der Ausarbeitung
- Zwei separate Vorträge





Anforderungen Ausarbeitung

Ausarbeitung

- Selbstständiges Verfassen einer Ausarbeitung von ≥ 10 Seiten
- Vollständiges Literaturverzeichnis
- Korrektes Zitieren
- Plagiarismus:

Die nicht gekennzeichnete übernahme fremder Inhalte führt zum sofortigen Ausschluss.

- Schriftgröße 12pt, übliche Seitenränder
- Titelseite mit Thema, Titel Proseminar, Semester, Name, Datum
- LATEX-Vorlage wird zur Verfügung gestellt
- Sprache Deutsch oder Englisch
- Korrekte Sprache wird vorausgesetzt:
 - ≥ 10 Fehler pro Seite ⇒ Abbruch der Korrektur





Anforderungen Vortrag

Vortrag

- 20-minütiger Vortrag
- Verfügbar: Beamer, Presenter, [Laptop]
- Zielgruppengerechte Präsentation der Inhalte
- übersichtliche Folien:
 - < 15 Textzeilen</p>
 - sinnvoller Einsatz von Farben
 - nummerierte Folien
- LATEX/beamer-Vorlage wird zur Verfügung gestellt
- Vortrag in Deutsch oder Englisch





Übersicht

Einführung

Termine

Algorithmen

Datenstrukturen



Themenauswahl

Verfahren

- Themenliste wurde/wird ausgehändigt
- Priorisierte Auswahl
- ggf. Angabe Wunschpartner(in)
- Abgabe hier oder bis 14. Oktober im Sekretariat Informatik 2/per Mail
- Wir bemühen uns (ohne Garantie) um ein "optimales" Matching
- Zuordnung der Themen und Betreuer bis Mitte nächster Woche online





Themenauswahl

Verfahren

- Themenliste wurde/wird ausgehändigt
- Priorisierte Auswahl
- ggf. Angabe Wunschpartner(in)
- Abgabe hier oder bis 14. Oktober im Sekretariat Informatik 2/per Mail
- Wir bemühen uns (ohne Garantie) um ein "optimales" Matching
- Zuordnung der Themen und Betreuer bis Mitte n\u00e4chster Woche online

Rücktritt vom Proseminar

- Bis zu drei Wochen nach Einführung: ohne Folgen
- Danach: Fehlversuch





Bibliothekseinführung

Einführung in die Literaturrecherche

- Einweisung in themenspezifische Literaturrecherche
- Dauer: ca. zwei Stunden
- Teilnahme für BSc-Studierende verpflichtend
- Bedarf bitte auf Themenblatt vermerken
- Termine zur Auswahl:
 - Dienstag, 06.11., 12 Uhr
 - Mittwoch, 07.11., 13 Uhr
 - Donnerstag, 08.11., 11 Uhr
 - Freitag, 09.11., 12 Uhr
- Mögliche Termine auf Themenliste vermerken, Bestätigung per Mail





Deadlines

Deadlines

Folgende Termine sind einzuhalten:

- 02.11.2018: letzte Rücktrittsmöglichkeit
- 12.11.2018: Vorlage der detaillierten Inhaltsübersicht
 - nicht: "1. Einleitung/2. Hauptteil/3. Schluss"
 - sondern: Strukturübersicht (Abschnittsüberschriften, wesentliche Beweise/Theoreme, ...) und Anfang des Hauptteils (eine Seite)
- 10.12.2018: vollständige Fassung der Ausarbeitung
- 14.01.2018: vollständige Fassung der Folien
- 31.01./01.02.2019: Blockseminar





Übersicht

Einführung

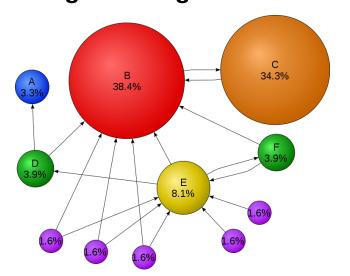
Termine

Algorithmen

Datenstrukturen



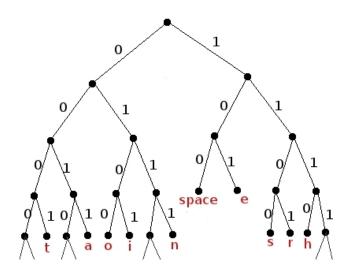
1. Pagerank-Algorithmus



- Algorithmus zur Analyse verlinkter Webseiten
- Allgemeiner: beliebige Graphen
- Basis: Bestimmung der Wahrscheinlichkeit, dass zufälliges Benutzerverhalten auf die Seite führt
- Benutzung in Google-Suchmaschine



2. Huffman-Kodierung

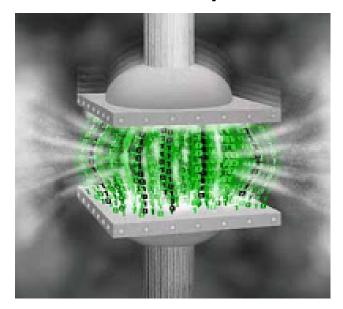


- Ziel: Erstellung einer Binärkodierung mit minimaler mittlerer Wortlänge benötigt
- Basis: Wahrscheinlichkeitsverteilung der einzelnen Zeichen
- Ansatz: Verwendung eines voll verzweigten Binärbaums zur Darstellung des Codes





3. LZW-Datenkompression

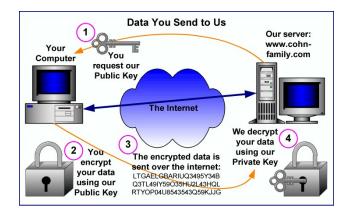


- Lempel-Ziv-Welch-Algorithmus
- Häufig bei Grafikformaten eingesetzt
- Verlustfrei
- Kompression mittels Wörterbüchern mit am häufigsten vorkommenden Zeichenketten
- Wörterbuch nicht zusätzlich gespeichert, sondern aus Datenstrom rekonstruiert





4. RSA-Kryptosystem

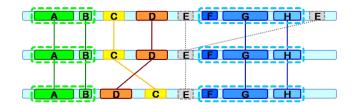


- Verfahren von Rivest, Shamir und Adleman (public-key encryption)
- Verwendung zur Verschlüsselung und digitalen Signatur
- Asymmetrisch: Schlüsselpaar privat/öffentlich
 - privat: zum Entschlüsseln oder Signieren
 - öffentlich: zur Verschlüsselung/ Signaturprüfung
- Privater Schlüssel wird geheim gehalten und kann nur mit extrem hohem Aufwand aus dem öffentlichen Schlüssel berechnet werden





5. Längste gemeinsame Teilsequenz

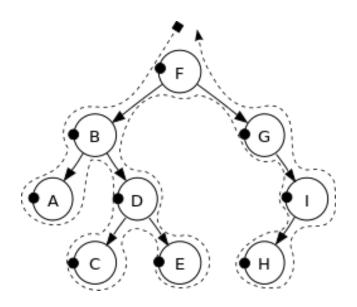


- Definition: längste gemeinsame (nicht notwendigerweise zusammenhängende) Teilsequenz mehrerer Zeichenketten
- Anwendungen: diff, Bioinformatik (Genanalyse)
- NP-hart f
 ür beliebige Anzahl von Zeichenketten
- Quadratische Komplexität für zwei Zeichenketten (dynamische Programmierung)





6. Deutsch-Schorr-Waite Baumtraversierung



- Klassische Lösung: Rekursion/Stack
- Ziel: Vermeidung des zusätzlichen Speicheraufwands
- Ansatz: Pointerrotation in der Heapdarstellung



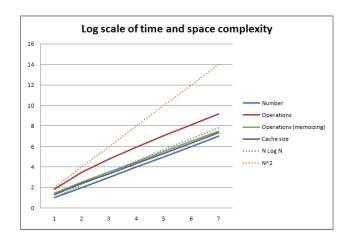
7. Problem der K kürzesten Pfade



- Problem: Finden der K kürzesten Pfade zwischen Knotenpaar in einem gerichteten Graphen
- Ansatz: Verallgemeinerung der Bellman-Gleichung



8. Amortisierte Laufzeitanalyse

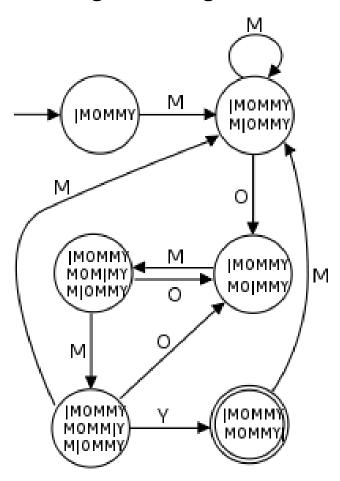


- Allgemeine Laufzeitanalyse: maximale Kosten der einzelnen Schritte
- Amortisierte Laufzeitanalyse: Worst Case aller
 Operationen im gesamten Durchlauf des Algorithmus
- Verbesserung der oberen Schranke bei seltenem Auftreten teurer Operationen
- Idee: der Worst Case ändert den Zustand der Datenstruktur so ab, dass er nicht wiederholt auftreten kann (z.B. dynamische Arrays)
- Drei unterschiedliche Berechnungsmethoden (Aggregat-, Account-, Potentialfunktion-Methode)





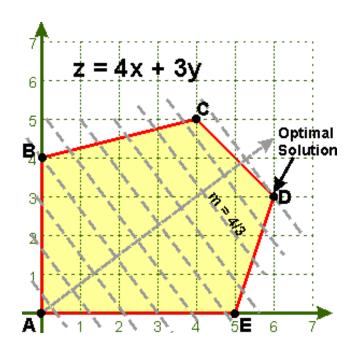
9. String Matching



- Ziel: Suche von Vorkommen eines Strings in einem (großen) Text
- Komplexität des naiven Algorithmus: |Text| · |String|
- Verbesserung durch Vorverarbeitung des Suchstrings



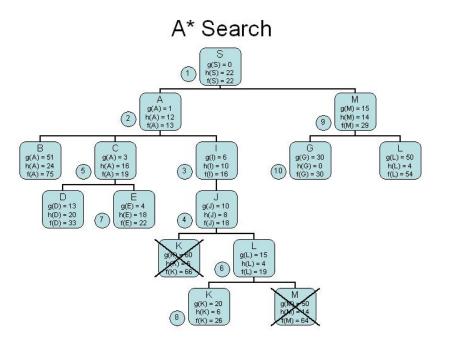
10. Lineare Optimierung (aka Lineare Programmierung)



- Ziel: Optimierung linearer Zielfunktionen über einer Menge, die durch lineare (Un-)Gleichungen eingeschränkt ist
- Simplexverfahren
- Ellipsoid-Methode



11. A*-Suchalgorithmus



- Berechnung eines kürzesten Pfades zwischen zwei Knoten in einem Graphen mit positiven Kantengewichten
- Verallgemeinerung und Erweiterung des Dijkstra-Algorithmus
- Schätzfunktion (Heuristik) zur zielgerichteten Suche



Übersicht

Einführung

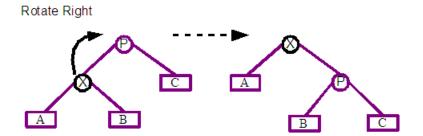
Termine

Algorithmen

Datenstrukturen



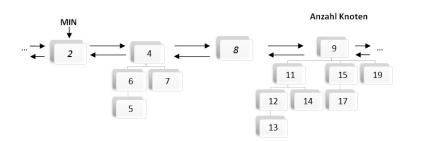
12. Splay Trees



- Baumorganisierte Datenstruktur
- Effizientes Einfügen, Suchen und Löschen von Elementen
- Ansatz: häufig benutzte Einträge nah an Wurzel platzieren
- Grundlegende Operation: splay (Rotieren eines Elements bis zur Wurzel)



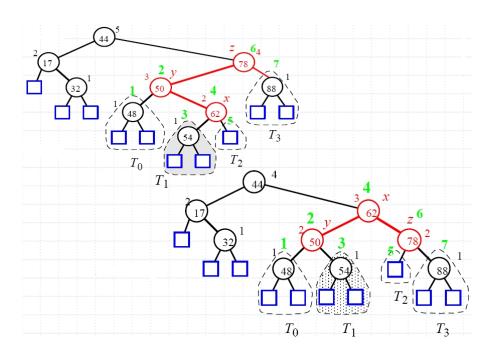
13. Fibonacci Heaps



- Datenstruktur zur Implementierung einer Vorrangwarteschlange (priority queue)
- Liste von geordneten Bäumen
- Heap-Bedingung: Priorität jedes Knotens mindestens so groß wie Priorität seiner Kinder
- (Fast) alle Operationen haben amortisiert konstante Laufzeit



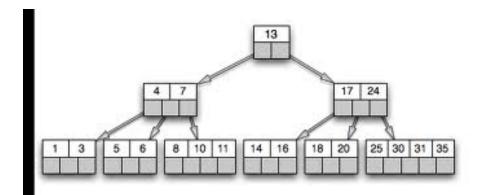
14. AVL-Bäume



- Balancierter binärer Suchbaum
- Invariante: maximaler
 Höhenunterschied der Teilbäume jedes
 Knotens ist 1
- Worst-Case-Komplexität der üblichen Operationen: O(log n)



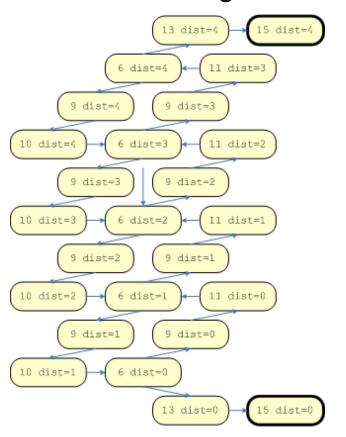
15. B-Bäume



- Immer vollständig balanciert
- Besonderheit: Anzahl der Knotennachfolger variabel (mit Obergrenze)
- Einsatz vor allem in Datenbanken und Dateisystemen



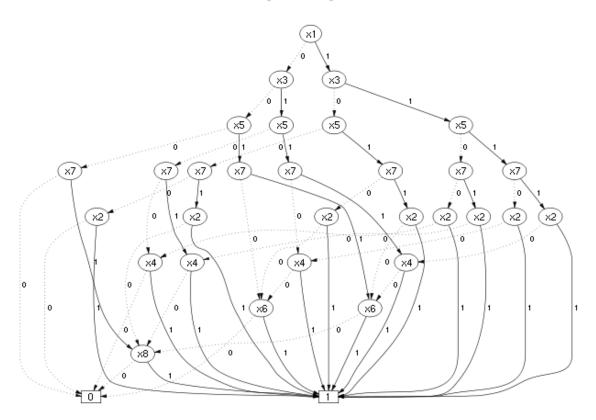
16. Bitstate Hashing



- Effiziente Darstellung von Zustandsräumen
- Problem: Erkennung von Zykeln
- Idee: Benutzung einer Hashfunktion, Speicherung von 0/1 im Hasharray
- Bis zu 98% Speicherersparnis im SPIN-Tool



17. Binäre Entscheidungsdiagramme

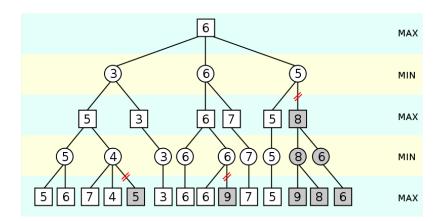


- Datenstruktur zur
 Darstellung Boolescher
 Funktionen
- Einsatz: Verifikation von (Hardware-)Systemen
- Effizient durch Sharing gemeinsamer Teilbäume
- Problem: Finden geeigneterVariablenordnungen





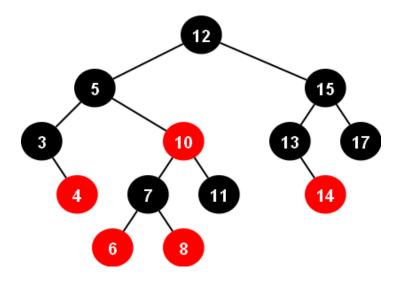
18. Spielbäume



- Darstellung von 2-Personen-Spielen mit abwechselnden Zügen (z.B. Schach, Go, Reversi, Dame, Mühle oder Vier gewinnt)
- Ziel: Bestimmung optimaler Strategien
- Minimax-Verfahren
- α - β -Pruning



19. Rot-Schwarz-Bäume

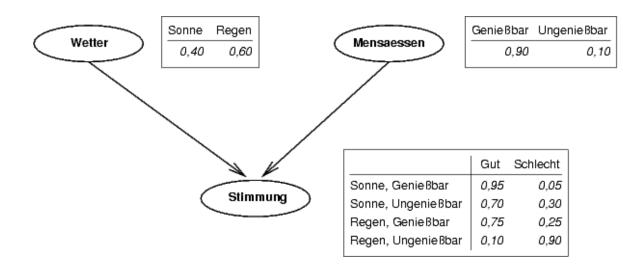


- Von binären Suchbäumen abgeleitet
- Fünf charakterisierende Eigenschaften:
 - 1. jeder Knoten ist rot oder schwarz
 - 2. Wurzel ist schwarz.
 - 3. alle Blätter sind schwarz.
 - 4. beide Kinder eines roten Knotens sind schwarz
 - 5. jeder Pfad von einem Knoten zu seinen Blattknoten enthält die gleiche Anzahl schwarzer Knoten
 - ⇒ annähernde Balancierung, effiziente Laufzeitschranken für Suchen/Einfügen/Löschen





20. Bayessche Netze



- Gerichteter azyklischer Graph (DAG)
 - Knoten = Zufallsvariablen
 - Kanten = bedingteAbhängigkeiten
- Kompakte Darstellung der gemeinsamen Wahrscheinlichkeitsverteilung aller Variablen
- Algorithmen:
 - Schließen (Inferenz)
 - Lernen



