

Algorithm Engineering 6

Messen und Vergleichen

Karsten Weicker

F IMN, HTWK Leipzig

- 1 Beispiel
- 2 Laufzeiten messen
- 3 Präsentation experimenteller Daten
- 4 Umgang mit Ausreißern
- 5 Statistische Aussagen
- 6 Vergleich mit asymptotischer Laufzeit

Überblick

- 1 Beispiel
- 2 Laufzeiten messen
- 3 Präsentation experimenteller Daten
- 4 Umgang mit Ausreißern
- 5 Statistische Aussagen
- 6 Vergleich mit asymptotischer Laufzeit

Beispiel

Quicksort

- Divide&Conquer-Lösung
- nach dem Lehrbuch von Weicker&Weicker
- Pivot-Element als Median von $A[links]$, $A[mitte]$ und $A[rechts]$

Shellsort

- Iteratives Insertionsort über Teilfolgen mit abnehmender Schrittweite
- Schrittweiten nach Ciura: 44842, 19930, 8858, 3937, 1750, 701, 301, 132, 57, 23, 10, 4, 1

Beispiel

Daten

- bis zu 130000 Elemente
- kein Wissen über eine Vorsortierung
- zwei unterschiedliche Datentypen für die Schlüsselwert:
 - Double
 - String: Länge 2000, nur Zeichen 'b', aber mit jeweils 2% Wahrscheinlichkeit 'a' und 'c', Stringvergleich ist selbst implementiert

Beispiel

Experimente

- $n = 2000, 10000, 18000, 26000, 34000, 42000, 50000, 58000, 66000, 74000, 82000, 90000, 98000, 106000, 114000, 122000, 130000$
- pro n : 40 Probleminstanzen, für die jeweils beide Algorithmen gemessen werden.
- Ermittlung der Mittelwerte und Standardabweichung (wenigstens!)

Überblick

- 1 Beispiel
- 2 Laufzeiten messen**
- 3 Präsentation experimenteller Daten
- 4 Umgang mit Ausreißern
- 5 Statistische Aussagen
- 6 Vergleich mit asymptotischer Laufzeit

Laufzeiten messen

Möglichkeiten in Java

- Messung mit

```
long start = System.currentTimeMillis();  
aufruf();  
long time = System.currentTimeMillis() - start;
```

- für kurze Perioden: `System.nanoTime()`

```
long start1 = System.nanoTime();  
long start2 = System.nanoTime();  
aufruf();  
long stop = System.nanoTime();  
long difference = stop - 2*start2 + start1;
```


Laufzeiten messen

Weitere Möglichkeiten in Java

- Klasse Stopwatch aus `org.apache.commons.lang.time`
- Schnittstelle MethodInterceptor von Spring

Laufzeiten messen

Hinweise für Java

- immer aus dem Programm heraus messen – nicht inklusive JRE-Start
- Just-in-time (JIT) Compiler verändert die gemessenen Zeiten durch Optimierung von Hot-Spots
 - unoptimiert: für jede Messung neue JRE starten
 - optimiert: erst 5–10 Durchläufe ohne Messung – danach messen
- bei mehreren sequentiellen Messungen in einer JRE: dazwischen `Systems.gc()` aufrufen

Laufzeiten messen

Speicherbedarf in Java messen

- über das Objekt der Klasse Runtime aus `java.lang`

```
Runtime runtime = Runtime.getRuntime();  
runtime.gc();  
long memory = runtime.totalMemory() -  
                runtime.freeMemory();
```

Überblick

- 1 Beispiel
- 2 Laufzeiten messen
- 3 Präsentation experimenteller Daten
- 4 Umgang mit Ausreißern
- 5 Statistische Aussagen
- 6 Vergleich mit asymptotischer Laufzeit

Präsentation experimenteller Daten

Grundsätzliches

- für Publikationen: immer schwarz/weiß
⇒ ist auch ohne Farbdrucker noch lesbar
- 2D
abgebildete räumliche Effekte können unterschiedlich interpretiert werden
- keine Animationen
- die Schlussfolgerung soll deutlich werden – es gibt keinen Schönheitspreis

Präsentation experimenteller Daten

Tabellen

- i.d.R. nicht für einzelne Messergebnisse
- Übersichtliche Darstellung der exakten Messwerte (Erwartungswert, Standardabweichung)
- ermöglicht spätere statistische Hypothesentests bzw. macht selbige nachvollziehbar
- Darstellung ist eher langweilig, nicht schnell intuitiv lesbar
- sollte immer durch Funktionsplots ergänzt werden

Präsentation experimenteller Daten

Beispiel: Double-Werte

- nur Mittelwerte

| $[10^{-6}s]$ | Quicksort | Shellsort |
|--------------|-----------|-----------|
| $n = 2000$ | 143.375 | 125.600 |
| $n = 10000$ | 775.225 | 764.050 |
| $n = 18000$ | 1447.125 | 1494.550 |
| $n = 26000$ | 2156.800 | 2252.175 |
| $n = 34000$ | 2852.625 | 3055.075 |
| $n = 42000$ | 3580.800 | 3866.225 |
| $n = 50000$ | 4313.475 | 4699.300 |
| $n = 58000$ | 5100.225 | 5555.600 |
| $n = 66000$ | 5817.550 | 6427.425 |
| $n = 74000$ | 6674.475 | 7355.950 |

Präsentation experimenteller Daten

Beispiel: String-Werte

- mit Standardabweichung für Hypothesentests

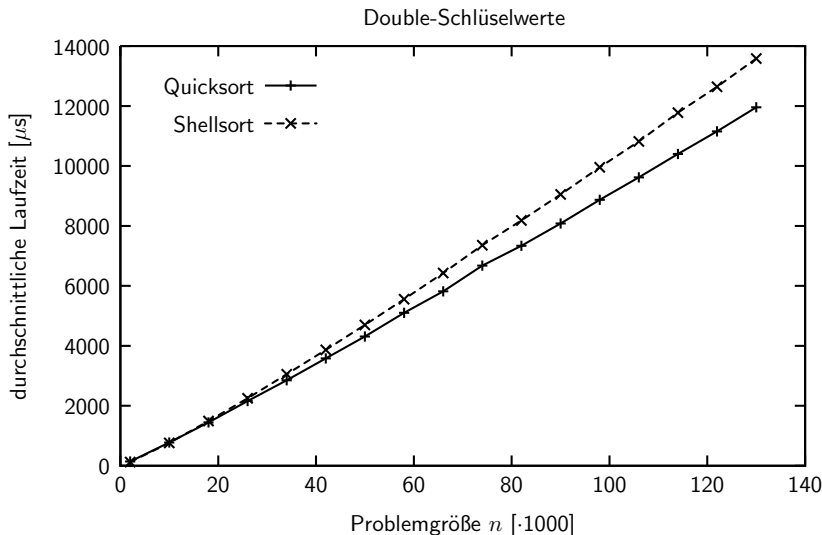
| $[10^{-3}s]$ | Quicksort | Shellsort |
|--------------|----------------------|----------------------|
| $n = 2000$ | 6.700 ± 0.458 | 1.600 ± 0.490 |
| $n = 10000$ | 37.525 ± 0.632 | 12.825 ± 2.587 |
| $n = 18000$ | 73.950 ± 2.549 | 35.625 ± 4.705 |
| $n = 26000$ | 111.600 ± 5.485 | 71.000 ± 8.680 |
| $n = 34000$ | 148.750 ± 6.390 | 102.150 ± 8.341 |
| $n = 42000$ | 188.900 ± 9.997 | 136.500 ± 10.663 |
| $n = 50000$ | 227.900 ± 11.766 | 170.075 ± 13.180 |
| $n = 58000$ | 268.500 ± 13.719 | 204.850 ± 15.570 |
| $n = 66000$ | 316.350 ± 13.780 | 250.050 ± 17.187 |
| $n = 74000$ | 360.275 ± 17.856 | 285.775 ± 19.605 |

Präsentation experimenteller Daten


2D-Graphen

- X-Achse: i.d.R. Größe der Eingabe
- Y-Achse: benötigte Zeit (Speicher etc.)

Präsentation experimenteller Daten



Präsentation experimenteller Daten




Präsentation experimenteller Daten

Unterschiede bei kleinem n

- Möglichkeit 1:
 - nur Ausschnitt der x-Werte plotten
 - ggf. große y-Werte abschneiden

Präsentation experimenteller Daten

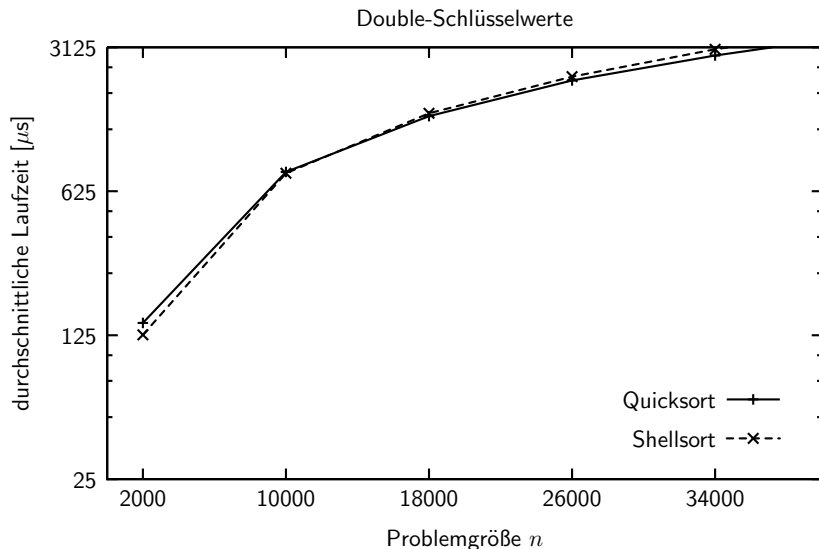


Präsentation experimenteller Daten

Unterschiede bei kleinem n

- Möglichkeit 2:
 - y-Achse logarithmisch skalieren
 - Vorsicht: Kurven sind nicht mehr intuitiv interpretierbar

Präsentation experimenteller Daten



Präsentation experimenteller Daten

Wichtig

- immer eine Legende (*key*) in einem weißen Bereich angeben
- Achsen beschriften – mit Einheiten
- keine kryptischen Abkürzungen
- zu kleine Schrift vermeiden
- Werte an den Achsen angeben
- nie mehr als 7 Kurven in ein Bild
- gerade Verbindungen implizieren keine Interpolation
aber immer: Messpunkte kennzeichnen!

Überblick

- 1 Beispiel
- 2 Laufzeiten messen
- 3 Präsentation experimenteller Daten
- 4 Umgang mit Ausreißern**
- 5 Statistische Aussagen
- 6 Vergleich mit asymptotischer Laufzeit

Umgang mit Ausreißern

Eigenschaften von Messungen

- Ausreißer = Einzelmessungen, die andere Charakteristik aufweisen
- Vermutung: andere Faktoren sind wirksam
- bei Laufzeiten: Garbage-Collector, Systemprozesse etc.
- diese Messungen können ein Ergebnis verfälschen

Umgang mit Ausreißern

Lösung 1: Konzentration auf mittlere Performance

- Technik: bei allen Messreihen werden die besten und schlechtesten Messungen nicht berücksichtigt
- Beispiel: Dezil = Zerlegung in 10 sortierte Bereiche – unberücksichtigt bleiben die Messungen im
 - oberen Dezil = beste 10% der Messwerte und im
 - unteren Dezil = schlechteste 10% der Messwerte

| n | Original | | jeweils –10% | |
|--------|----------|------|--------------|------|
| | Erw. | Anz. | Erw. | Anz. |
| 2000 | 6.700 | 40 | 6.750 | 32 |
| 10000 | 37.525 | 40 | 37.500 | 32 |
| 18000 | 73.950 | 40 | 73.625 | 32 |
| 26000 | 111.600 | 40 | 111.094 | 32 |
| 34000 | 148.750 | 40 | 147.688 | 32 |
| 42000 | 188.900 | 40 | 187.531 | 32 |
| 50000 | 227.900 | 40 | 226.031 | 32 |
| 58000 | 268.500 | 40 | 266.938 | 32 |
| 66000 | 316.350 | 40 | 316.469 | 32 |
| 74000 | 360.275 | 40 | 359.000 | 32 |
| 82000 | 411.175 | 40 | 409.813 | 32 |
| 90000 | 450.800 | 40 | 450.313 | 32 |
| 98000 | 499.050 | 40 | 496.781 | 32 |
| 106000 | 528.325 | 40 | 529.438 | 32 |
| 114000 | 574.275 | 40 | 573.594 | 32 |
| 122000 | 608.025 | 40 | 607.063 | 32 |
| 130000 | 655.300 | 40 | 654.406 | 32 |

Umgang mit Ausreißern

Lösung 2: statistische Identifikation

- Technik I:
 - Annahme: die Messwerte sind annähernd normalverteilt mit Erwartungswert μ und Standardabweichung σ
 - alle Messwerte die außerhalb des Bereichs $[\mu - \sigma, \mu + \sigma]$ nicht berücksichtigen

| n | Original | | jenseits \pm sdv | | | | jeweils -10% | |
|--------|----------|------|--------------------|------|----|---|-----------------|------|
| | Erw. | Anz. | Erw. | Anz. | < | > | Erw. | Anz. |
| 2000 | 6.700 | 40 | 7.000 | 28 | 12 | 0 | 6.750 | 32 |
| 10000 | 37.525 | 40 | 37.486 | 37 | 1 | 2 | 37.500 | 32 |
| 18000 | 73.950 | 40 | 73.400 | 30 | 4 | 6 | 73.625 | 32 |
| 26000 | 111.600 | 40 | 110.667 | 24 | 8 | 8 | 111.094 | 32 |
| 34000 | 148.750 | 40 | 146.419 | 31 | 2 | 7 | 147.688 | 32 |
| 42000 | 188.900 | 40 | 186.241 | 29 | 4 | 7 | 187.531 | 32 |
| 50000 | 227.900 | 40 | 224.710 | 31 | 3 | 6 | 226.031 | 32 |
| 58000 | 268.500 | 40 | 264.071 | 28 | 4 | 8 | 266.938 | 32 |
| 66000 | 316.350 | 40 | 317.607 | 28 | 7 | 5 | 316.469 | 32 |
| 74000 | 360.275 | 40 | 361.607 | 28 | 8 | 4 | 359.000 | 32 |
| 82000 | 411.175 | 40 | 411.250 | 28 | 7 | 5 | 409.813 | 32 |
| 90000 | 450.800 | 40 | 449.538 | 26 | 7 | 7 | 450.313 | 32 |
| 98000 | 499.050 | 40 | 496.667 | 30 | 5 | 5 | 496.781 | 32 |
| 106000 | 528.325 | 40 | 529.296 | 27 | 6 | 7 | 529.438 | 32 |
| 114000 | 574.275 | 40 | 573.433 | 30 | 5 | 5 | 573.594 | 32 |
| 122000 | 608.025 | 40 | 607.867 | 30 | 6 | 4 | 607.063 | 32 |
| 130000 | 655.300 | 40 | 655.097 | 31 | 5 | 4 | 654.406 | 32 |

Umgang mit Ausreißern

Lösung 2: statistische Identifikation

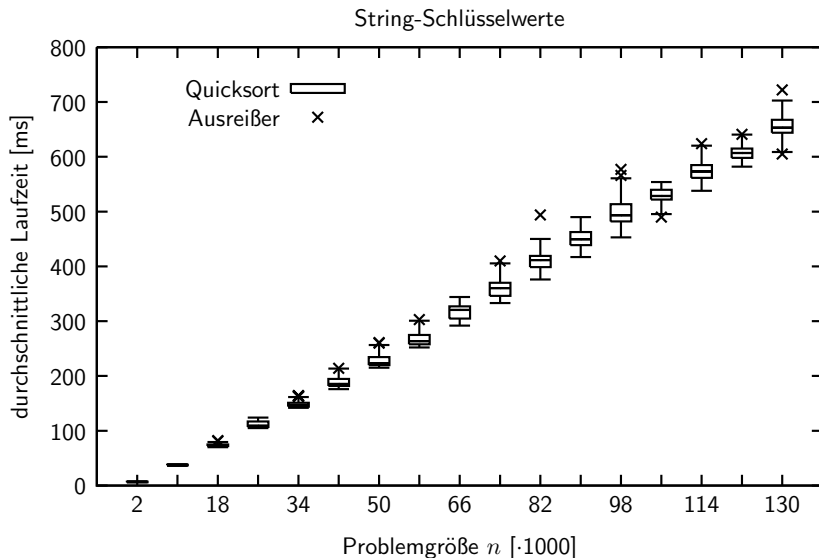
- Technik II:

- betrachten Median $Q_{0.5}$ und Quartilen $Q_{0.25}$ und $Q_{0.75}$
- Werte außerhalb des Bereichs
 $[Q_{0.25} - 1.5 \cdot (Q_{0.75} - Q_{0.25}), Q_{0.75} + 1.5 \cdot (Q_{0.75} - Q_{0.25})] = [a, b]$

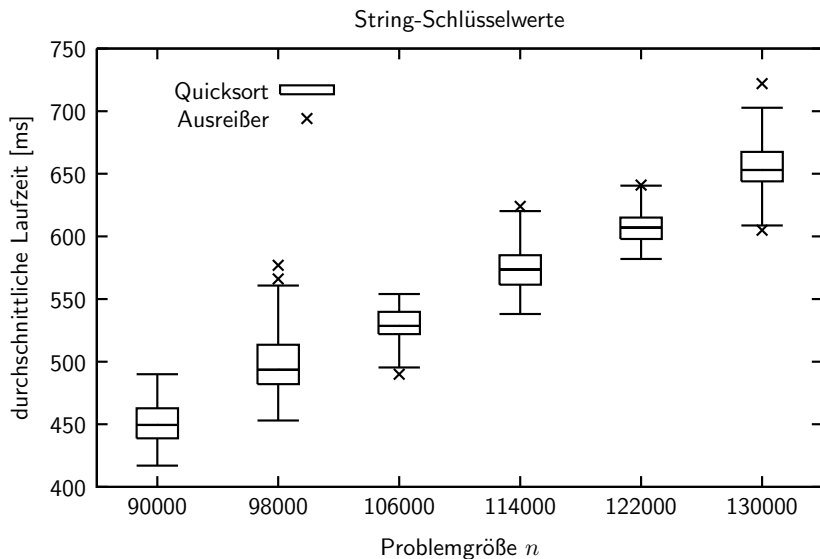
nicht berücksichtigen

- Grafische Darstellung: Boxplot
 - Rechtecke mit Linie markieren Median und Quartile
 - Whiskers markieren $\min\{b, t_{\max}\}$ und $\max\{a, t_{\min}\}$
 - Ausreißer werden eingezeichnet

Umgang mit Ausreißern



Umgang mit Ausreißern



Beispiel
○○○Messen
○○○○Präsentieren
ooooooooooooAusreißer
oooooooo●Statistik
ooooooooooooAsymptotisch
oooooo

| n | Orig. | jens. 3-Quart.Diff. | | | | jens. \pm sdv | | jeweils -10% | |
|--------|---------|---------------------|------|---|---|-----------------|------|--------------|------|
| | Erw. | Erw. | Anz. | < | > | Erw. | Anz. | Erw. | Anz. |
| 2000 | 6.700 | 6.700 | 40 | 0 | 0 | 7.000 | 28 | 6.750 | 32 |
| 10000 | 37.525 | 37.525 | 40 | 0 | 0 | 37.486 | 37 | 37.500 | 32 |
| 18000 | 73.950 | 73.553 | 38 | 0 | 2 | 73.400 | 30 | 73.625 | 32 |
| 26000 | 111.600 | 111.600 | 40 | 0 | 0 | 110.667 | 24 | 111.094 | 32 |
| 34000 | 148.750 | 147.111 | 36 | 0 | 4 | 146.419 | 31 | 147.688 | 32 |
| 42000 | 188.900 | 188.256 | 39 | 0 | 1 | 186.241 | 29 | 187.531 | 32 |
| 50000 | 227.900 | 226.184 | 38 | 0 | 2 | 224.710 | 31 | 226.031 | 32 |
| 58000 | 268.500 | 267.615 | 39 | 0 | 1 | 264.071 | 28 | 266.938 | 32 |
| 66000 | 316.350 | 316.350 | 40 | 0 | 0 | 317.607 | 28 | 316.469 | 32 |
| 74000 | 360.275 | 359.000 | 39 | 0 | 1 | 361.607 | 28 | 359.000 | 32 |
| 82000 | 411.175 | 409.051 | 39 | 0 | 1 | 411.250 | 28 | 409.813 | 32 |
| 90000 | 450.800 | 450.800 | 40 | 0 | 0 | 449.538 | 26 | 450.313 | 32 |
| 98000 | 499.050 | 495.237 | 38 | 0 | 2 | 496.667 | 30 | 496.781 | 32 |
| 106000 | 528.325 | 529.308 | 39 | 1 | 0 | 529.296 | 27 | 529.438 | 32 |
| 114000 | 574.275 | 573.000 | 39 | 0 | 1 | 573.433 | 30 | 573.594 | 32 |
| 122000 | 608.025 | 607.179 | 39 | 0 | 1 | 607.867 | 30 | 607.063 | 32 |
| 130000 | 655.300 | 654.868 | 38 | 1 | 1 | 655.097 | 31 | 654.406 | 32 |

Überblick

- 1 Beispiel
- 2 Laufzeiten messen
- 3 Präsentation experimenteller Daten
- 4 Umgang mit Ausreißern
- 5 Statistische Aussagen**
- 6 Vergleich mit asymptotischer Laufzeit

Statistische Aussagen

Empirische Forschung

- Erkenntnisse beruhen auf Erfahrungen
- z.B. Beobachtung, Experiment & Induktion
- Problem: Einzelbeobachtungen (deskriptive Aussage) vs. allgemeine Gesetzmäßigkeiten
- Explikative Aussage: Generalisierung aus einzelnen Beobachtungen
- Anwendung von Hypothesentests
- Beispiel: „*Der Hypothesentest zeigt, dass Algorithmus A schneller als Algorithmus B ist (mit einem Fehler von 2%).*“

Statistische Aussagen

Algorithmen vergleichen mit Hypothesentests

- Messungen zu zwei Algorithmen A_1 (x_1, \dots, x_n) und A_2 (y_1, \dots, y_m) — *wichtig: alle Messungen mit gleicher Problemgröße!*
- Mittelwerte der Messungen: μ_1 und μ_2
- falls $\mu_1 < \mu_2$: Zufall? Wiederholt beobachtbar?
- Null-Hypothese H_0 : $\tilde{\mu}_1 \geq \tilde{\mu}_2$
- Alternativ-Hypothese H_1 : $\tilde{\mu}_1 < \tilde{\mu}_2$
- statistischer Hypothesentest: versucht Null-Hypothese zu widerlegen und gibt einen Fehler α (Signifikanzniveau) für den Irrtum an

Statistische Aussagen

Zweistichproben-t-Test für abhängige Stichproben

- x_i und y_i wurden auf derselben Problem Instanz i gemessen ($n = m$)
- berechne Differenz: $d_i = x_i - y_i$
- $H_0: \tilde{\mu}_d \leq 0; H_1: \tilde{\mu}_d > 0$
- Annahme: Werte d_i seien normalverteilt (Erwartungswert μ_d und Standardabw. σ_d)
- t-Wert: $t = \sqrt{n} \frac{\mu_d - 0}{\sigma_d}$
- Nullhypothese ablehnen, wenn $t > t(1 - \alpha, n - 1)$

Statistische Aussagen

Beispiel: Double-Schlüsselwerte, $n = 2000$

Anderer Rechner! andere Messreihe!

- Quicksort: $\mu_1 = 891.625$, $\sigma_1 = 40.994$
- Shellsort: $\mu_2 = 727.9$, $\sigma_2 = 37.603$
- Differenz: $\mu_d = 163.725$, $\sigma_d = 59.050$
- t-Wert: $t = \sqrt{40} \frac{163.725}{59.050} = 17.536$
- Signifikanzniveau $\alpha = 0.999$, d.h. maximale Irrtumswahrscheinlichkeit von 0.01
- Nullhypothese abgelehnt wegen:
 $t(0.999, 39) \approx 3.313 < t$

⇒ Shellsort ist hier schneller als Quicksort

Statistische Aussagen

Beispiel: Double-Schlüsselwerte, $n = 18000$

Anderer Rechner! andere Messreihe!

- Shellsort: $\mu_1 = 9332.775$, $\sigma_1 = 65.496$
- Quicksort: $\mu_2 = 9164.4$, $\sigma_2 = 122.965$
- Differenz: $\mu_d = 168.375$, $\sigma_d = 139.202$
- t-Wert: $t = \sqrt{40} \frac{168.375}{139.202} = 7.65$
- Signifikanzniveau $\alpha = 0.999$, d.h. maximale Irrtumswahrscheinlichkeit von 0.01
- Nullhypothese abgelehnt wegen:
 $t(0.999, 39) \approx 3.313 < t$

⇒ Quicksort ist hier schneller als Shellsort

| Anz. der Freih. grade | $(1 - \alpha)$ für zweiseitigen Test | | | | | | | |
|--------------------------------|--------------------------------------|-------|-------|-------|--------|--------|--------|---------|
| | 0,5 | 0,75 | 0,8 | 0,9 | 0,95 | 0,98 | 0,99 | 0,998 |
| | $(1 - \alpha)$ für einseitigen Test | | | | | | | |
| | 0,75 | 0,875 | 0,90 | 0,95 | 0,975 | 0,99 | 0,995 | 0,999 |
| 1 | 1,000 | 2,414 | 3,078 | 6,314 | 12,706 | 31,821 | 63,657 | 318,309 |
| 2 | 0,816 | 1,604 | 1,886 | 2,920 | 4,303 | 6,965 | 9,925 | 22,327 |
| 3 | 0,765 | 1,423 | 1,638 | 2,353 | 3,182 | 4,541 | 5,841 | 10,215 |
| 4 | 0,741 | 1,344 | 1,533 | 2,132 | 2,776 | 3,747 | 4,604 | 7,173 |
| 5 | 0,727 | 1,301 | 1,476 | 2,015 | 2,571 | 3,365 | 4,032 | 5,893 |
| 6 | 0,718 | 1,273 | 1,440 | 1,943 | 2,447 | 3,143 | 3,707 | 5,208 |
| 7 | 0,711 | 1,254 | 1,415 | 1,895 | 2,365 | 2,998 | 3,499 | 4,785 |
| 8 | 0,706 | 1,240 | 1,397 | 1,860 | 2,306 | 2,896 | 3,355 | 4,501 |
| 9 | 0,703 | 1,230 | 1,383 | 1,833 | 2,262 | 2,821 | 3,250 | 4,297 |
| 10 | 0,700 | 1,221 | 1,372 | 1,812 | 2,228 | 2,764 | 3,169 | 4,144 |
| 11 | 0,697 | 1,214 | 1,363 | 1,796 | 2,201 | 2,718 | 3,106 | 4,025 |
| 12 | 0,695 | 1,209 | 1,356 | 1,782 | 2,179 | 2,681 | 3,055 | 3,930 |
| 13 | 0,694 | 1,204 | 1,350 | 1,771 | 2,160 | 2,650 | 3,012 | 3,852 |
| 14 | 0,692 | 1,200 | 1,345 | 1,761 | 2,145 | 2,624 | 2,977 | 3,787 |
| 15 | 0,691 | 1,197 | 1,341 | 1,753 | 2,131 | 2,602 | 2,947 | 3,733 |

| Anz. der Freih. grade | $(1 - \alpha)$ für zweiseitigen Test | | | | | | | |
|--------------------------------|--------------------------------------|-------|-------|-------|-------|-------|-------|-------|
| | 0,5 | 0,75 | 0,8 | 0,9 | 0,95 | 0,98 | 0,99 | 0,998 |
| | $(1 - \alpha)$ für einseitigen Test | | | | | | | |
| | 0,75 | 0,875 | 0,90 | 0,95 | 0,975 | 0,99 | 0,995 | 0,999 |
| 16 | 0,690 | 1,194 | 1,337 | 1,746 | 2,120 | 2,583 | 2,921 | 3,686 |
| 17 | 0,689 | 1,191 | 1,333 | 1,740 | 2,110 | 2,567 | 2,898 | 3,646 |
| 18 | 0,688 | 1,189 | 1,330 | 1,734 | 2,101 | 2,552 | 2,878 | 3,610 |
| 19 | 0,688 | 1,187 | 1,328 | 1,729 | 2,093 | 2,539 | 2,861 | 3,579 |
| 20 | 0,687 | 1,185 | 1,325 | 1,725 | 2,086 | 2,528 | 2,845 | 3,552 |
| 21 | 0,686 | 1,183 | 1,323 | 1,721 | 2,080 | 2,518 | 2,831 | 3,527 |
| 22 | 0,686 | 1,182 | 1,321 | 1,717 | 2,074 | 2,508 | 2,819 | 3,505 |
| 23 | 0,685 | 1,180 | 1,319 | 1,714 | 2,069 | 2,500 | 2,807 | 3,485 |
| 24 | 0,685 | 1,179 | 1,318 | 1,711 | 2,064 | 2,492 | 2,797 | 3,467 |
| 25 | 0,684 | 1,178 | 1,316 | 1,708 | 2,060 | 2,485 | 2,787 | 3,450 |
| 26 | 0,684 | 1,177 | 1,315 | 1,706 | 2,056 | 2,479 | 2,779 | 3,435 |
| 27 | 0,684 | 1,176 | 1,314 | 1,703 | 2,052 | 2,473 | 2,771 | 3,421 |
| 28 | 0,683 | 1,175 | 1,313 | 1,701 | 2,048 | 2,467 | 2,763 | 3,408 |
| 29 | 0,683 | 1,174 | 1,311 | 1,699 | 2,045 | 2,462 | 2,756 | 3,396 |
| 30 | 0,683 | 1,173 | 1,310 | 1,697 | 2,042 | 2,457 | 2,750 | 3,385 |

| Anz. der Freih. grade | $(1 - \alpha)$ für zweiseitigen Test | | | | | | | |
|--------------------------------|--------------------------------------|-------|-------|-------|-------|-------|-------|-------|
| | 0,5 | 0,75 | 0,8 | 0,9 | 0,95 | 0,98 | 0,99 | 0,998 |
| | $(1 - \alpha)$ für einseitigen Test | | | | | | | |
| | 0,75 | 0,875 | 0,90 | 0,95 | 0,975 | 0,99 | 0,995 | 0,999 |
| 40 | 0,681 | 1,167 | 1,303 | 1,684 | 2,021 | 2,423 | 2,704 | 3,307 |
| 50 | 0,679 | 1,164 | 1,299 | 1,676 | 2,009 | 2,403 | 2,678 | 3,261 |
| 60 | 0,679 | 1,162 | 1,296 | 1,671 | 2,000 | 2,390 | 2,660 | 3,232 |
| 70 | 0,678 | 1,160 | 1,294 | 1,667 | 1,994 | 2,381 | 2,648 | 3,211 |
| 80 | 0,678 | 1,159 | 1,292 | 1,664 | 1,990 | 2,374 | 2,639 | 3,195 |
| 90 | 0,677 | 1,158 | 1,291 | 1,662 | 1,987 | 2,368 | 2,632 | 3,183 |
| 100 | 0,677 | 1,157 | 1,290 | 1,660 | 1,984 | 2,364 | 2,626 | 3,174 |
| 200 | 0,676 | 1,154 | 1,286 | 1,653 | 1,972 | 2,345 | 2,601 | 3,131 |
| 300 | 0,675 | 1,153 | 1,284 | 1,650 | 1,968 | 2,339 | 2,592 | 3,118 |
| 400 | 0,675 | 1,152 | 1,284 | 1,649 | 1,966 | 2,336 | 2,588 | 3,111 |
| 500 | 0,675 | 1,152 | 1,283 | 1,648 | 1,965 | 2,334 | 2,586 | 3,107 |
| ∞ | 0,674 | 1,150 | 1,282 | 1,645 | 1,960 | 2,326 | 2,576 | 3,090 |

Statistische Aussagen

Zweistichproben-t-Test für unabhängige Stichproben

- unterschiedliche Probleminstanzen und/oder $n \neq m$
- Annahme: x_i und y_i sind normalverteilt
- $H_0: \tilde{\mu}_x - \tilde{\mu}_y \leq 0$; $H_1: \tilde{\mu}_x - \tilde{\mu}_y > 0$
- t-Wert: $t = \sqrt{\frac{nm}{n+m}} \cdot \frac{\mu_x - \mu_y - 0}{\sigma}$ mit
$$\sigma = \sqrt{\frac{(n-1)\sigma_x^2 + (m-1)\sigma_y^2}{n+m-2}}$$
- Nullhypothese ablehnen, wenn $t > t(1 - \alpha, n + m - 2)$

Statistische Aussagen

Beispiel: Double-Schlüsselwerte, $n = 18000$

- je 10% Ausreißer entfernt, d.h. $n = m = 32$
- Shellsort: $\mu_1 = 9319.813$, $\sigma_1 = 25.971$
- Quicksort: $\mu_2 = 9155.156$, $\sigma_2 = 82.983$
- gemeinsame Sdv:

$$\sigma = \sqrt{\frac{(31)25.971^2 + (31)82.983^2}{32+32-2}} = 61.484$$

- t-Wert:

$$t = \sqrt{\frac{32 \cdot 32}{32+32}} \cdot \frac{9319.813 - 9155.156 - 0}{61.484} = 10.71211$$

- Nullhypothese abgelehnt wegen:

$$t(0.999, 78) \approx 3.198 < t$$

⇒ Quicksort ist hier schneller als Shellsort

Statistische Aussagen

Veränderte Rahmenbedingungen

- Beispiel: ein Algorithmus wird auf speziellen Daten angewandt
- Frage: wirkt sich die Spezifik der Daten (im Gegensatz zu zufälligen Daten) auf die Laufzeit aus?
- zweiseitiger Test – $H_0: \tilde{\mu}_1 = \tilde{\mu}_2$; $H_1: \tilde{\mu}_1 \neq \tilde{\mu}_2$
- Test ist analog – nur mit dem zweiseitigen Vertrauensbereich in den t-Quantil-Tabellen

Statistische Aussagen

Irrtumswahrscheinlichkeit

- der erlaubte Fehler für einen Hypothesentest wird vorgegeben
- sog. Signifikanzniveau α
- typische Werte:
 - $\alpha \leq 0.05$: signifikanter Unterschied
 - $\alpha \leq 0.01$: hoch signifikanter Unterschied
 - $\alpha \leq 0.001$: höchst signifikanter Unterschied

Statistische Aussagen

Bessere Testverfahren

- Wilcoxon-Vorzeichen-Rang-Test (Wilcoxon signed-rank test) – eine Population, weniger strikte Voraussetzungen
- Mann-Whitney-Wilcoxon Test – X und Y beziehen sich auf unterschiedliche Populationen
- Software: SPSS, Matlab, Mathematica, R
- Beispiel in R: `wilcox.test(x, y, paired = TRUE, alternative = "greater")`

Überblick

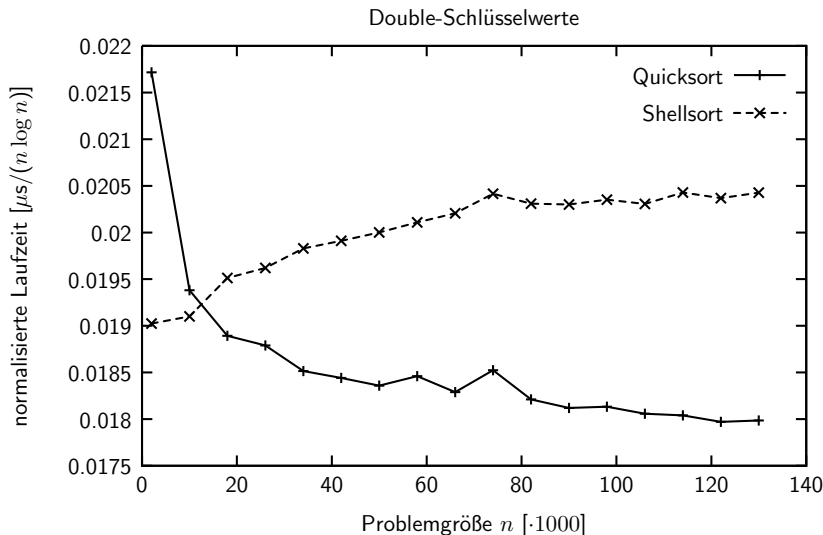
- 1 Beispiel
- 2 Laufzeiten messen
- 3 Präsentation experimenteller Daten
- 4 Umgang mit Ausreißern
- 5 Statistische Aussagen
- 6 Vergleich mit asymptotischer Laufzeit

Vergleich mit asymptotischer Laufzeit

Präsentation experimenteller Daten

- Y-Achse zur theoretischen Laufzeit skalieren
- Technik: alle Datenpunkte durch die asymptotische Laufzeit teilen
- dann: alle Kurven müssten waagerecht sein
- im Beispiel:
 - bei Quicksort: $n \log n$ (im Average-Case)
 - bei Shellsort mit Ciura-Schrittfolge: unbekannt

Vergleich mit asymptotischer Laufzeit

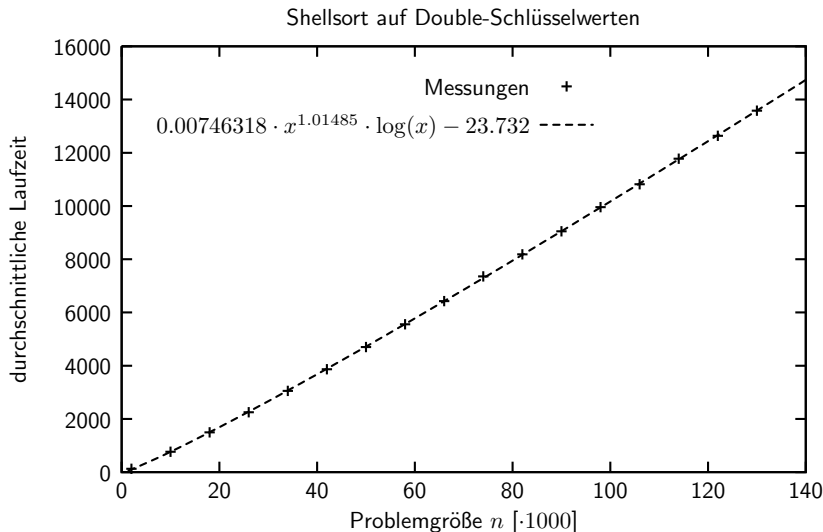


Vergleich mit asymptotischer Laufzeit

Empirisch gestütztes Laufzeitmodell: Ping-Pong-Regression

- 1 Laufzeiten messen
- 2 Ein Modell mit offenen Konstanten formulieren
z.B.: $f(x) = a \cdot x^b$
- 3 per Regression (z.B. in Matlab, R, Gnuplot)
das Modell an die Messdaten angleichen lassen
- 4 vorherige Schritte solange (mit
unterschiedlichen Startwerten für die
Konstanten oder anderen Modellen) iterieren,
bis Datenpunkte und Kurven tendentiell passen

Vergleich mit asymptotischer Laufzeit




Vergleich mit asymptotischer Laufzeit

Zweites Beispiel: Branch&Bound

- Backtracking-Algorithmus für TSP, der Branch&Bound benutzt
- Backtracking selbst hat Laufzeit $\Theta(n!)$
- Welche Laufzeit erreicht der Branch&Bound-Algorithmus?

Vergleich mit asymptotischer Laufzeit

Bestes Ergebnis in Gnuplot



$$f(x) = a \cdot x^b, \quad a = 6.6 \cdot 10^{-15}, \quad b = 12,9$$

⇒ unzureichende Qualität