

Änderungen verwalten mit `git`

PeP et al. Toolbox Workshop



PeP et al. e.V.

Physikstudierende und
ehemalige Physikstudierende
der TU Dortmund

2024

Was ist Versionskontrolle?

- Versionskontrollsoftware speichert Änderungen an Dokumenten / Dateien
- Das kann fast alles sein:
 - Software
 - Rechtliche Dokumente
 - Dokumentation
 - Wissenschaftliche Veröffentlichungen
 - Bilder
 - Baupläne, CAD-Zeichnungen
 - ...
- Ein *Schnappschuss* eines Projektes nennt man *Revision*
- Alle Revisionen zusammen bilden die *Geschichte* des Projekts

Warum also Versionskontrolle nutzen?

- Erlaubt, an eine beliebige Revision zurückzukehren
- Kann die Unterschiede zwischen Revisionen anzeigen
- Macht Zusammenarbeit an Projekten einfacher
- Dient auch als Backup

Warum also Versionskontrolle nutzen?

Versionskontrollsoftware macht die Beantwortung der folgenden Fragen einfach:

Was? Was wurde von Revision *A* auf Revision *B* geändert

Wer? Wer hat eine Änderung gemacht? Wer hat alles zum Projekt beigetragen?

Warum? Warum wurde diese Änderung gemacht?

Wann? Wann wurde ein bestimmter Bug eingeführt bzw. behoben?

Warum also Versionskontrolle nutzen?

Versionskontrollsoftware macht die Beantwortung der folgenden Fragen einfach:

Was? Was wurde von Revision A auf Revision B geändert

Wer? Wer hat eine Änderung gemacht? Wer hat alles zum Projekt beigetragen?


Warum? Warum wurde diese Änderung gemacht?

Wann? Wann wurde ein bestimmter Bug eingeführt bzw. behoben?

Versionskontrolle ist eine fundamentale Bedingung
für nachvollziehbare, reproduzierbare Wissenschaft.

Wie arbeitet man am besten an einem Protokoll
zusammen?

Idee: Austausch über Mails / Messenger




- Risiko, dass Änderungen vergessen werden, ist groß
- Bei jedem Abgleich muss jemand anders aktiv werden
 - Stört
 - Es kommt zu Verzögerungen

Fazit: Eine sehr unbequeme / riskante Lösung

Idee: Austausch über Cloud Speicher


Dropbox, Google Drive, OneDrive, Nextcloud, iCloud, ...



- Man merkt nichts von Änderungen der Anderen
- Gleichzeitige Änderungen führen zu „In Konflikt stehende Kopie“-Dateien
- Änderungen werden nicht zusammengeführt
- Keine echte Historie des Projekts

Fazit: Besser, aber hat deutliche Probleme

Lösung: Änderungen verwalten mit **git**



git

- Ein Versionskontrollsystem
- Ursprünglich entwickelt, um den Programmcode des Linux-Kernels zu verwalten (Linus Torvalds)
- Hat sich gegenüber ähnlichen Programmen (SVN, mercurial) durchgesetzt
- Wird in der Regel über die Kommandozeile benutzt
- Es gibt auch Plugins für Editoren, z.B. VS Code


Was bringt git für Vorteile?

- Arbeit wird für andere sichtbar protokolliert
- Erlaubt Zurückspringen an einen früheren Zeitpunkt
- Kann die meisten Änderungen automatisch zusammenfügen
- Wirkt nebenbei auch als Backup

Einzige Herausforderung: Man muss lernen, damit umzugehen

Zentrales Konzept: Das Repository


- Erzeugen mit `git init`
- Damit wird der aktuelle Ordner zu einem Repository




Aktuelles Arbeitsverzeichnis, Inhalt des Ordners im Dateisystem.

Zentrales Konzept: Das Repository

- Erzeugen mit `git init`
- Damit wird der aktuelle Ordner zu einem Repository




Aktuelles Arbeitsverzeichnis, Inhalt des Ordners im Dateisystem.



Änderungen, die für einen „commit“ vorgemerkt sind.

Zentrales Konzept: Das Repository

- Erzeugen mit `git init`
- Damit wird der aktuelle Ordner zu einem Repository



Aktuelles Arbeitsverzeichnis, Inhalt des Ordners im Dateisystem.




Änderungen, die für einen „commit“ vorgemerkt sind.



Gespeicherte *Historie* des Projekts. Alle jemals gemachten Änderungen. Ein Baum von Commits.

Zentrales Konzept: Das Repository

- Erzeugen mit `git init`
- Damit wird der aktuelle Ordner zu einem Repository




Aktuelles Arbeitsverzeichnis, Inhalt des Ordners im Dateisystem.

Änderungen, die für einen „commit“ vorgemerkt sind.

Gespeicherte *Historie* des Projekts. Alle jemals gemachten Änderungen. Ein Baum von Commits.

Zentrales Konzept: Das Repository

- Erzeugen mit `git init`
- Damit wird der aktuelle Ordner zu einem Repository




Aktuelles Arbeitsverzeichnis, Inhalt des Ordners im Dateisystem.

Änderungen, die für einen „commit“ vorgemerkt sind.

Gespeicherte *Historie* des Projekts. Alle jemals gemachten Änderungen. Ein Baum von Commits.


Remotes

Remotes sind zentrale Stellen, z. B. Server auf denen die History gespeichert wird.




Remotes

Remotes sind zentrale Stellen, z. B. Server auf denen die History gespeichert wird.




Konzept: Commits

- Stand des Repositories zu einem Zeitpunkt
- Erlaubt das Hinzufügen von Kommentaren: Was wurde getan seit dem letzten Commit?
- Sind die *Versionen* des Repositories




a ← b ← c ← d ← main


- **Commit**: Zustand/Inhalt des Arbeitsverzeichnisses zu einem Zeitpunkt
 - Enthält Commit-Message (Beschreibung der Änderungen)
 - Wird über einen Hash-Code identifiziert
 - Zeigt immer auf seine(n) Vorgänger



- **Commit**: Zustand/Inhalt des Arbeitsverzeichnisses zu einem Zeitpunkt
 - Enthält Commit-Message (Beschreibung der Änderungen)
 - Wird über einen Hash-Code identifiziert
 - Zeigt immer auf seine(n) Vorgänger
- **Branch**: benannter Zeiger auf einen Commit
 - Entwicklungszweig
 - Im Praktikum reicht meist der Standard-Branch: **main**
 - Wandert weiter mit dem aktuellsten Commit



- **Commit**: Zustand/Inhalt des Arbeitsverzeichnisses zu einem Zeitpunkt
 - Enthält Commit-Message (Beschreibung der Änderungen)
 - Wird über einen Hash-Code identifiziert
 - Zeigt immer auf seine(n) Vorgänger
- **Branch**: benannter Zeiger auf einen Commit
 - Entwicklungszweig
 - Im Praktikum reicht meist der Standard-Branch: **main**
 - Wandert weiter mit dem aktuellsten Commit



- **Commit**: Zustand/Inhalt des Arbeitsverzeichnisses zu einem Zeitpunkt
 - Enthält Commit-Message (Beschreibung der Änderungen)
 - Wird über einen Hash-Code identifiziert
 - Zeigt immer auf seine(n) Vorgänger
- **Branch**: benannter Zeiger auf einen Commit
 - Entwicklungszweig
 - Im Praktikum reicht meist der Standard-Branch: **main**
 - Wandert weiter mit dem aktuellsten Commit
- **Tag**: unveränderbarer Zeiger auf einen Commit
 - Wichtiges Ereignis, z.B. veröffentlichte Version

1. Neues Repo? Repository erzeugen oder klonen:
Repo schon da? Änderungen herunterladen:

```
git init, git clone  
git pull
```

2. Arbeiten

- 2.1 Dateien bearbeiten und testen
- 2.2 Änderungen vorbereiten:
- 2.3 Änderungen als *commit* speichern:

```
git add  
git commit
```


3. Commits anderer herunterladen und integrieren:

```
git pull
```

4. Eigene Commits hochladen:

```
git push
```

Zum selber ausprobieren und Lernen:



<https://learngitbranching.js.org/>

Der Start: git init, git clone

<code>git init</code>	initialisiert ein <code>git</code> -Repo im jetzigen Verzeichnis
<code>git clone url</code>	klont das Repo aus <code>url</code>
<code>rm -rf .git</code>	löscht alle Spuren von <code>git</code> aus dem Repository, nicht reversibel ohne Backup, wird eigentlich nie gebraucht

Was passiert in Git: `git status`, `git log`

<code>git status</code>	zeigt Status des Repos (welche Dateien sind neu, gelöscht, verschoben, bearbeitet)
<code>git status -s</code>	Kurzform von <code>git status</code> , zeigt Liste von geänderten Dateien
<code>git log</code>	listet Commits in aktuellem Branch. Hat viele Optionen.

Staging Bereich: `git add`, `git mv`, `git rm`, `git reset`

<code>git add file ...</code>	fügt Dateien/Verzeichnisse zum Staging-Bereich hinzu
<code>git add -p ...</code>	fügt Teile einer Datei zum Staging-Bereich hinzu
<code>git add -u ...</code>	fügt <i>alle</i> von Git getrackten und vom User veränderten Dateien zum Staging-Bereich hinzu
<code>git mv</code>	wie <code>mv</code> (automatisch in Staging)
<code>git rm</code>	wie <code>rm</code> (automatisch in Staging)
<code>git reset file</code>	entfernt Dateien/Verzeichnisse aus Staging

<code>git diff</code>	zeigt Unterschiede zwischen Staging und Arbeitsverzeichnis
<code>git diff --staged</code>	zeigt Unterschiede zwischen letzten Commit und Staging
<code>git diff <i>commit1</i> <i>commit2</i></code>	zeigt Unterschiede zwischen zwei Commits

<code>git commit</code>	erzeugt Commit aus jetzigem Staging-Bereich, öffnet Editor für Commit-Message
<code>git commit -m "message"</code>	Commit mit <i>message</i> als Message
<code>git commit --amend</code>	letzten Commit ändern (fügt aktuellen Staging hinzu, Message bearbeitbar)

Niemals commits ändern, die schon in den main branch gepusht sind!

- Wichtig: Sinnvolle Commit-Messages
 - Erster Satz ist Zusammenfassung (ideal < 50 Zeichen)
 - Danach eine leere Zeile lassen
 - Dann längere Erläuterung des commits
- Logische Commits erstellen, für jede logische Einheit ein Commit
 - `git add -p` ist hier nützlich
- Hochgeladene Commits sollte man nicht mehr ändern

Mit der remote History (dem Server) interagieren

`git pull` Commits herunterladen

`git push` Commits hochladen

Don't Panic

Entstehen, wenn `git` nicht automatisch mergen kann (selbe Zeile geändert, etc.)

1. Die betroffenen Dateien öffnen
2. Markierungen finden und die Stelle selbst mergen (meist wenige Zeilen)

```
<<<<<< HEAD
foo
|||||| merged common ancestors
bar
=====
baz
>>>>>> Commit-Message
```

3. Merge abschließen:

3.1 `git add ...` (Files mit behobenen Konflikten)

3.2 `git commit` → Editor wird geöffnet

3.3 Vorgeschlagene Nachricht kann angenommen werden (In vim `":wq"` eintippen)

Nützlich: `git config --global merge.conflictstyle zdiff3`

Zu früheren Versionen zurückkehren

`git checkout commit` Commit ins Arbeitsverzeichnis laden
`git restore filename` Änderungen an Dateien verwerfen (zum letzten Commit zurückkehren)

`git stash` Änderungen kurz zur Seite schieben
`git stash pop` Änderungen zurückholen aus Stash

.gitignore

- Man möchte nicht alle Dateien von **git** beobachten lassen
- z.B. **build**-Ordner

Lösung: **.gitignore**-Datei

- einfache Textdatei
- enthält Regeln für Dateien, die nicht beobachtet werden sollen

Beispiel:

```
build/  
*.pdf  
__pycache__/
```

GitHub

- größter Hoster
- viele open-source Projekte
- Unbegrenzt private Repositories für Studenten und Forscher:
education.github.com

Bitbucket

- kostenlose private Repos mit höchstens fünf Leuten
- keine Speicherbegrenzungen
- Hängt was Oberfläche und Funktionen angeht, den beiden anderen weit hinterher

GitLab

- open-source
- keine Begrenzungen an privaten Repos
- kann man selbst auf einem eigenen Server betreiben

Weitere Open Source Optionen, auch zum selbst hosten: Gitea, Forgejo

GitHub

- größter Hoster
- viele open-source Projekte
- Unbegrenzt private Repositories für Studenten und Forscher:
education.github.com

Bitbucket

- kostenlose private Repos mit höchstens fünf Leuten
- keine Speicherbegrenzungen
- Hängt was Oberfläche und Funktionen angeht, den beiden anderen weit hinterher

GitLab

- open-source
- keine Begrenzungen an privaten Repos
- kann man selbst auf einem eigenen Server betreiben

Weitere Open Source Optionen, auch zum selbst hosten: Gitea, Forgejo

„Now, everybody sort of gets born with a GitHub account“ – Guido van Rossum

Git kann auf mehrere Arten mit einem Server kommunizieren:

- HTTPS** → Mit Nutzernamen / Passwort: War lange die einfachste Möglichkeit. Wird aber von GitHub aus Sicherheitsgründen nicht mehr einfach unterstützt.
- Mit „Personal Access Token“. Neues Verfahren für GitHub über HTTPS.
- SSH** : Keys müssen erzeugt und eingestellt werden, Passwort für den Key muss, wenn ein „SSH-Agent“ verwendet wird, nur einmal pro Session eingegeben werden.

SSH-Keys:

1. `ssh-keygen -t ed25519 -C "your_email@example.com"`
2. Passwort wählen
3. `cat ~/.ssh/id_ed25519.pub`
4. Ausgabe ist Public-Key, beim Server eintragen (im Browser)

Für den Agent, falls noch nicht vom Betriebssystem eingerichtet (z. B. Windows mit WSL):

5. `echo 'eval $(ssh-agent -s)' >> ~/.bashrc`
6. `echo 'AddKeysToAgent yes' >> ~/.ssh/config`

Doku: <https://docs.github.com/en/authentication/connecting-to-github-with-ssh>

Extra Slide für sauberere Projekt Historien: `git pull --rebase` (optional)

Vielfaches Merging und Merge Konflikte erzeugen eine etwas nichtlineare Projekt-Historie, denn:
`git pull` entspricht `git fetch origin; git merge ...` (→ gemergter Branch bleibt erhalten)

Alternativ kann man **`git pull --rebase`** ausführen, welches (in etwa) äquivalent ist zu
`git fetch origin; git rebase ...` (→ lokale Commits werden auf neue Commits angewendet).

Achtung: Um einen Merge Konflikt bei **`git pull --rebase`** abzuschließen, muss **`git rebase --continue`** anstelle von `git commit -m "..."` ausgeführt werden! Also einfach genau lesen was Git empfiehlt ;)

Dies hat Vorteile:

- Die Projekt-Historie ist linearer
- Es gibt weniger merge-commits

aber auch (kleinere) Nachteile:

- Es ist hinterher nicht mehr sichtbar, wer einen Merge Konflikt wie behoben hat
- Die Abfolge der Commits entspricht nicht mehr der wahren Entwicklungshistorie

Entscheidet man sich für pulls mit Rebase als Standard, muss Git anders konfiguriert werden:

`git config --global pull.rebase true`, dann wird bei allen folgenden `git pull` Befehlen ein Rebase gemacht

Im Rahmen einer Schulung ist 2021 eine Videoaufzeichnung einer ausführlicheren Git-Einführung angefertigt worden, die auf diesem Kurs basiert:

Teil 1 <https://www.youtube.com/watch?v=R2BC0tPwtXc>

Teil 2 <https://www.youtube.com/watch?v=ZEcklfIp6Og>