

021-Rust-CLI-Logauswertung

Rust- und Systemaufgabe
Anforderungsniveau: Einfach

1 Ziel der Aufgabe

Sie schreiben ein kleines Kommandozeilenwerkzeug in Rust, das eine Zugriffs-Logdatei zeilenweise einliest und daraus ein paar Kennzahlen berechnet. Geprüft wird weniger der Umfang als die Sorgfalt: ein Parser, der auch die unangenehmen Zeilen aushält, und ein eigener Fehlertyp statt `unwrap`.

Veranschlagte Bearbeitungszeit: 2–3 Stunden.

Verwendete Techniken:

- Rust in der Edition, die `cargo new` anlegt (2021 oder 2024), Aufbau als Binärprojekt mit Bibliotheksteil
- Argumentbehandlung mit `clap` (Derive-API)
- Eigener Fehlertyp mit `thiserror`, Rückgabe über `Result`
- Unit-Tests mit `#[cfg(test)]`

2 Aufgabenbeschreibung

1. Projekt aufsetzen

Legen Sie ein neues Cargo-Projekt an:

```
cargo new logstat && cd logstat
cargo add clap --features derive
cargo add thiserror
```

Teilen Sie den Code in `src/lib.rs` (Parser und Auswertung) und `src/main.rs` (Argumente, Ein- und Ausgabe) auf – nur so lässt sich die Auswertung testen, ohne einen Prozess zu starten.

2. Logformat verstehen

Eingabe ist das Combined Log Format, wie es Apache und nginx schreiben. Eine Zeile sieht so aus:

```
192.0.2.10 - - [12/Mar/2024:08:15:42 +0100] "GET /api/kunden?seite=2 HTTP/1.1" 200
5312 "https://example.invalid/start" "Mozilla/5.0"
```

Die Felder in dieser Reihenfolge: Client-Adresse, Identd (ungenutzt), Benutzername, Zeitstempel in eckigen Klammern, Anfragezeile in Anführungszeichen, Statuscode, Antwortgröße in Bytes (- bei leerer Antwort), Referrer, User-Agent. Interessant sind nur vier davon:

```
#[derive(Debug, Clone, PartialEq)]
pub struct Eintrag {
    pub adresse: String,
```

```

    pub pfad: String,
    pub status: u16,
    pub bytes: u64,
}

pub fn zeile_parsen(nr: usize, zeile: &str) -> Result<Eintrag, LogFehler>;

```

Ein Abfrageteil im Pfad (alles ab `?`) wird abgeschnitten, damit `/api/kunden?seite=2` und `?seite=3` als derselbe Pfad zählen; ein `-` im Byte-Feld gilt als 0. Eine fertige Parserbibliothek für Logzeilen ist nicht erlaubt – ob Sie `split`, einen Zustandsautomaten oder `regex` nehmen, bleibt Ihnen überlassen.

3. Fehlertyp definieren

Er unterscheidet zwischen einem Ein-/Ausgabefehler und einer nicht lesbaren Zeile und nennt bei einer kaputten Zeile deren Nummer.

```

#[derive(Debug, thiserror::Error)]
pub enum LogFehler {
    #[error("Datei nicht lesbar: {0}")]
    Datei(#[from] std::io::Error),
    #[error("Zeile {zeile}: unerwartetes Format ({grund})")]
    Format { zeile: usize, grund: String },
}

```

Im Bibliotheksteil gibt es kein `unwrap`, `expect` oder `panic!` auf Eingabedaten – fehlerhafte Eingaben sind ein erwarteter Fall, kein Programmierfehler.

4. Kennzahlen berechnen

Eine Funktion nimmt die eingelesenen Einträge entgegen und liefert eine Auswertung:

```

pub struct Auswertung {
    pub zeilen_gesamt: usize,
    pub zeilen_ungueltig: usize,
    pub bytes_gesamt: u64,
    pub nach_statusklasse: BTreeMap<String, usize>, // "2xx", "3xx", ...
    pub top_pfade: Vec<(String, usize)>,           // die fuenf haeufigsten
}

```

Die Rangliste enthält die fünf häufigsten Pfade; bei gleicher Häufigkeit wird alphabetisch nach dem Pfad sortiert, damit zwei Läufe dieselbe Ausgabe erzeugen.

5. Kommandozeile und Ausgabe

Der Aufruf ist `logstat <DATEI>`: ein Pflichtargument, dazu das von `clap` erzeugte `--help`. Ungültige Zeilen werden übersprungen, aber gezählt und am Ende ausgewiesen. Die Kennzahlen gehen nach `stdout`, Warnungen und Fehlermeldungen nach `stderr`. Der Exit-Code ist 0 bei erfolgreicher Auswertung und 1, wenn die Eingabe nicht lesbar ist (Datei fehlt, keine Rechte).

Die Ausgabe ist schlichter Text; ausgefeilte Spaltenausrichtung erwarten wir nicht. Ein Vorschlag:

```

Zeilen gesamt: 12841 (davon ungueltig: 7)
Bytes gesamt: 412350992
2xx: 11204   3xx: 912   4xx: 718
Top-Pfade:  /api/kunden 3120 /start 2044

```

6. Tests schreiben

Vier Unit-Tests genügen, aber sie sollen etwas aussagen:

- eine gültige Zeile wird feldgenau zerlegt
- `/suche?q=abc` wird zu `/suche` und `-` im Byte-Feld ergibt 0
- ein Leerzeichen innerhalb der Anführungszeichen verschiebt die folgenden Felder nicht – Status und Bytes bleiben korrekt
- eine abgeschnittene Zeile liefert `LogFehler::Format` mit der richtigen Zeilennummer

Schreiben Sie die Logzeilen in den Tests als Rohzeichenkette (`r#"..."#`), sonst ersticken Sie in Maskierungen. Prüfen Sie Fehlerfälle über die Variante, nicht über den Meldungstext.

3 Anforderungen

- Das Projekt übersetzt mit `cargo build` ohne Warnungen.
- Parser und Auswertung liegen in `src/lib.rs` und sind ohne Prozessstart testbar. Ein Fehlertyp mit `thiserror` unterscheidet die Fälle und nennt die Zeilennummer.
- **Kein `unwrap`, `expect` oder `panic!` auf Eingabedaten** im Bibliotheksteil. In Tests sind sie erlaubt.
- Kennzahlen nach `stdout`, Meldungen nach `stderr`. Die Exit-Codes 0 und 1 sind wie beschrieben belegt.
- Mindestens vier Unit-Tests; `cargo test` läuft grün.

4 Abgabe

- Git-Repository ohne `target/` (`.gitignore` anlegen).
- `beispiel/zugriff.log` mit etwa zehn erfundenen Zeilen, darunter eine fehlerhafte. Nur Adressen aus den Dokumentationsbereichen (192.0.2.0/24, 198.51.100.0/24, 203.0.113.0/24) und `example.invalid`, keine echten Logzeilen.
- Eine kurze `README.md` mit dem Startbefehl (`cargo run -- beispiel/zugriff.log`) und den beiden Exit-Codes. Das Projekt läuft danach ohne weitere Handgriffe.

5 Bewertungskriterien

- **Fehlerbehandlung** – durchdachter Fehlertyp, oder endet jeder Sonderfall in `unwrap`? Bleibt das Programm bei einer kaputten Zeile handlungsfähig?
- **Parserqualität** – werden Anführungszeichen, Leerzeichen im Pfad und das `-` in den Zahlenfeldern korrekt behandelt?
- **Testtiefe** – prüfen die Tests auch die unangenehmen Fälle oder nur die eine Zeile, die ohnehin funktioniert?
- **Trennung der Belange** – ist die Auswertung von Ein- und Ausgabe getrennt, oder steckt die halbe Logik in `main`?