Bibliotheken

Hochleistungs-Ein-/Ausgabe

Michael Kuhn

Wissenschaftliches Rechnen
Fachbereich Informatik
Universität Hamburg

2017-05-26

Universität Hamburg
DER FORSCHUNG | DER LEHRE | DER BILDUNG

E/A-Schichten

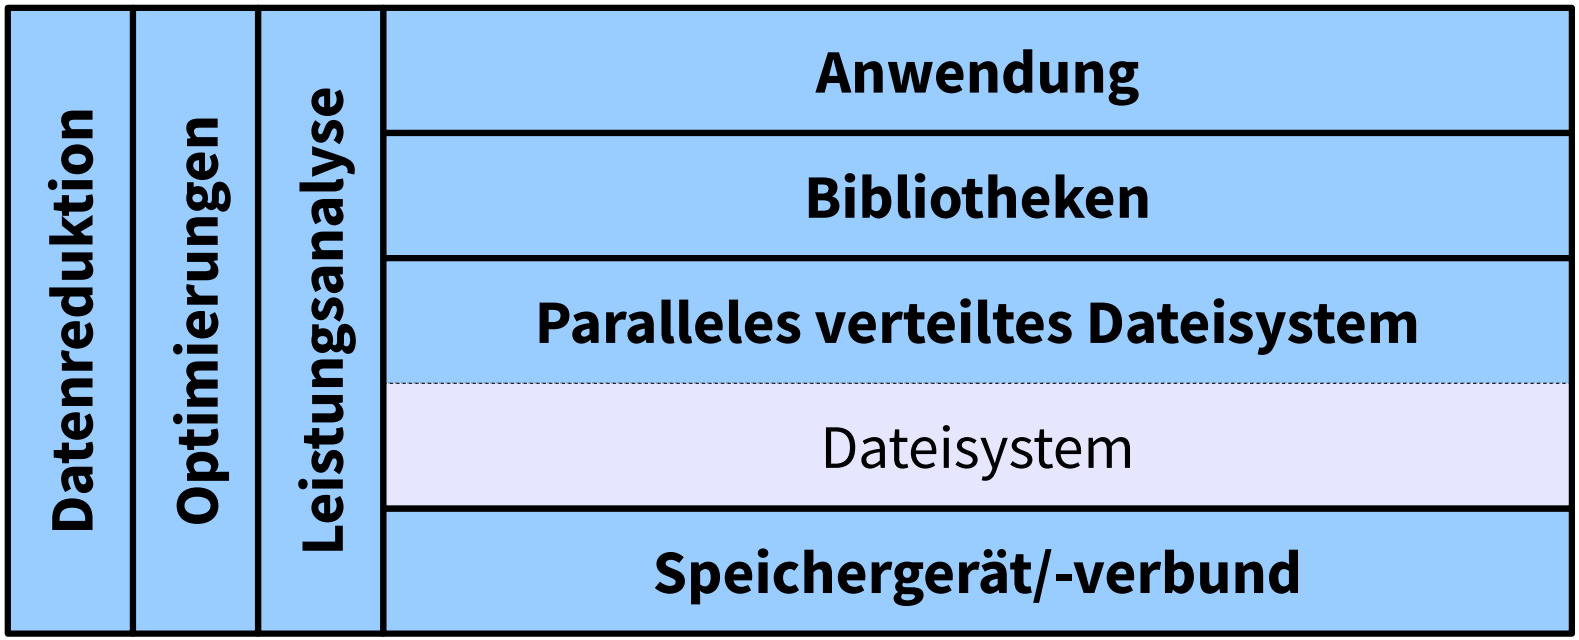

Abbildung: E/A-Schichten

Überblick

- POSIX und MPI-IO können für parallele E/A genutzt werden
  - Beide Schnittstellen sind allerdings nicht sehr komfortabel
  - Byte- bzw. element-orientierter Zugriff
- Probleme bestehender Schnittstellen
  - Austauschbarkeit von Daten
  - Aufwendige Programmierung
  - Leistungsprobleme

Überblick…

- Bibliotheken stellen zusätzliche Funktionalität bereit
  - Selbstbeschreibende Daten
  - Interne Strukturierung
  - Abstrakte E/A-Definition
- Umgehung von Leistungsproblemen
  - Verursacht beispielsweise durch zu strikte Semantik

Überblick…

- Vorteile
  - Portabilität der Daten
  - Komfortable Benutzung
  - Einfachheit der Programmierung
- Nachteile
  - Zusätzliche Schichten benötigt
  - Komplexes Zusammenspiel

Ansätze

- Leistungssteigerung
  - SIONlib
- Selbstbeschreibende Datenformate
  - NetCDF (Network Common Data Form)
  - HDF (Hierarchical Data Format)
- Abstrakte E/A-Definition
  - ADIOS (Adaptable IO System)

Überblick

- SIONlib bietet effizienten Zugriff auf prozess-lokale Dateien
- Zugriffe werden auf eine oder wenige physikalische Dateien abgebildet
  - Je nachdem was optimale Leistung verspricht
  - Ausrichtung an Dateisystemblöcken/-streifen
    - Ziel: Reduzierung/Eliminierung von Sperrenoverhead
- Möglichst rückwärtskompatibel
  - Wrapper für `fread` und `fwrite`
  - Öffnen und Schließen mit speziellen Funktionen

Überblick…

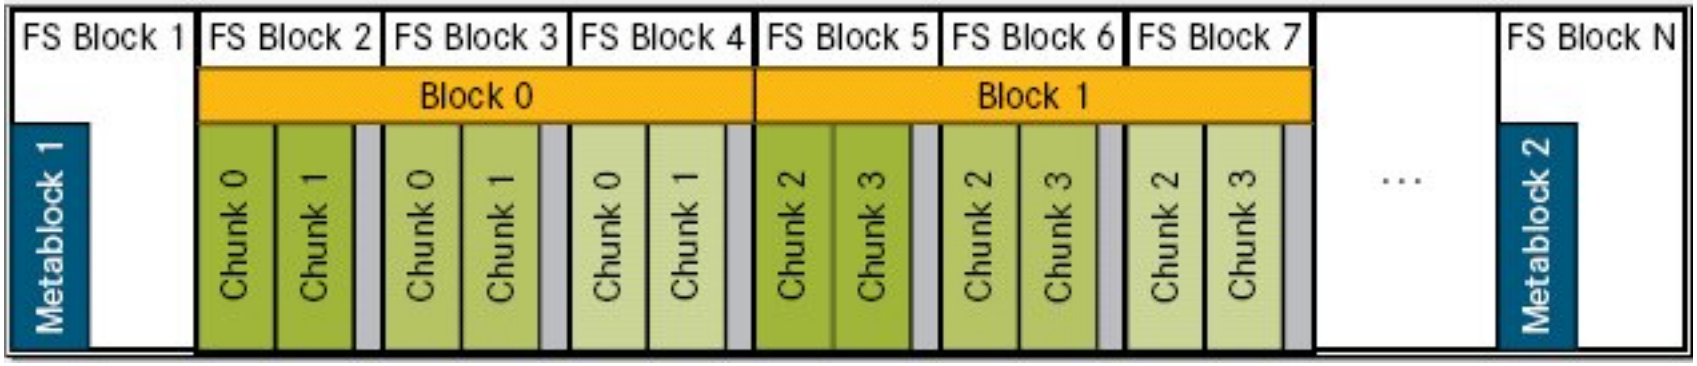

Abbildung: SIONlib-Dateiformat [2]

- Metablock 1: Statische Metadaten (beim Öffnen geschrieben)
- Metablock 2: Dynamische Metadaten (beim Schließen geschrieben)
- Jeder Block enthält Daten eines Prozesses (unterteilt in Chunks)

Beispiel

```
1  int fd;
2  FILE* fp;
3
4  fd = sion_paropen_mpi(..., &numfiles, ..., &chunksize,
       ↪ &fsblocksize, ..., &fp, ...);
5
6  for (...)
7  {
8      fwrite(..., fp);
9  }
10
11 sion_parclose_mpi(fd);
```

Listing 1: SIONlib-Beispiel für parallelen Zugriff

- `numfiles` gibt die Anzahl der zu verwendenden Dateien an (-1 für automatische Bestimmung)
- `chunksize` gibt die maximale Größe eines Schreibaufrufs an
- `fsblocksize` gibt die Größe eines Dateisystemblocks/-streifens an (-1 für automatische Bestimmung)

Funktionalität

- Mehrere Zugriffsmodi
  - Kollektives Öffnen mit `sion_paropen_mpi`
  - Nicht-kollektives Öffnen mit `sion_open_rank`
  - Serieller Zugriff via `sion_open` und `sion_close`
- Intelligente Abbildung und Ausrichtung
  - Zusammenhängende Blöcke pro Prozess
  - Abbildung auf internes Dateilayout

Zusammenfassung

- SIONlib existiert hauptsächlich um Unzulänglichkeiten existierender Dateisysteme zu umgehen
- Einerseits Probleme mit vielen Dateien
  - Geringe Metadatenleistung
  - Dafür hohe Datenleistung
- Andererseits gemeinsame Dateien häufig langsam
  - POSIX macht Sperren notwendig
  - Korrektes Zugriffsmuster sehr wichtig

Überblick

- Entwickelt vom Unidata Program Center
  - University Corporation for Atmospheric Research
- Projekt wurde 1989 gestartet
  - Basiert auf dem Common Data Format der NASA
- Hauptsächlich in wissenschaftlichen Anwendungen
  - Insbesondere in den Klimawissenschaften, der Meteorologie und der Ozeanographie
- Besteht aus Bibliotheken und Datenformaten

Datenformate

- Es exisitieren drei Formate
  1. Klassisches Format (CDF-1)
  2. Klassisches Format mit 64-Bit-Offsets (CDF-2)
  3. NetCDF-4-Format
- Datenformate sind offene Standards
- Klassisches und 64-Bit-Format sind internationale Standards des Open Geospatial Consortiums

Datenformate…

- Das klassische und 64-Bit-Format sind eigenständig
  - NetCDF-4 nutzt HDF5
- Mehrere Optionen für parallele E/A
  - NetCDF-4 unterstützt parallele E/A für NetCDF-4-Dateien
  - Parallele E/A für das klassische und 64-Bit-Format mit aktuellen NetCDF-Versionen (4.1.1+) oder Parallel-NetCDF
- Parallel-NetCDF hat eine inkompatible Schnittstelle

Funktionalität

- Schnittstellen für viele Sprachen
  - C, Fortran, C++, Java, R, Perl, Python, Ruby etc.
- Datenformat ist architekturunabhängig
  - Endianness-Konvertierung
- NetCDF unterstützt Gruppen und Variablen
  - Gruppen enthalten Variablen
  - Variablen enthalten Daten
- Zusätzliche Attribute für Variablen

Funktionalität…

- Unterstützung für mehrdimensionale Arrays
  - `char`, `byte`, `short`, `int`, `float`, `double`
  - NetCDF-4: `ubyte`, `ushort`, `uint`, `int64`, `uint64`, `string`
- Größe der Dimensionen ist beliebig
  - Bei klassischem und 64-Bit-Format nur eine unbeschränkt
    - Beispiel: Matrix kann nur in der Zeitdimension wachsen
  - Bei NetCDF-4 beliebig viele unbeschränkt

Funktionalität…

- Zusätzliche Funktionen
  - Transparente Kompression
- Diverse Werkzeuge verfügbar
  - Beispielsweise `ncdump` um Daten auszugeben
  - NetCDF Operators (NCO)

Beispiel

```
netcdf ... {
dimensions:
    time = UNLIMITED ; // (8760 currently)
variables:
    double time(time) ;
        string time:units = "days" ;
        string time:long_name = "Julian_date" ;

// global attributes:
        string :Conventions = "None" ;
        string :creation_date = "Wed Jul 16 12:52:44 CEST
            ↪ 2014" ;
}
```

Listing 2: ncdump-Ausgabe

Funktionsweise

1. Datei anlegen mit `nc_create`
   - Paralleler Zugriff mit `nc_create_par`
2. Dimensionen definieren mit `nc_def_dim`
3. Gruppen definieren mit `nc_def_grp`
4. Variablen definieren mit `nc_def_var`
5. Attribute schreiben mit `nc_put_att_*`
6. Variablen schreiben mit `nc_put_var_*`
7. Datei schließen mit `nc_close`

Funktionsweise...

- Lesen unterscheidet zwei Fälle
  1. Dateistruktur ist bekannt
  2. Dateistruktur ist unbekannt

1. Öffnen der Datei mit `nc_open`
   - Paralleler Zugriff mit `nc_open_par`
2. Gruppen-IDs auslesen mit `nc_inq_ncid`
3. Variablen-IDs auslesen mit `nc_inq_varid`
4. Variablen auslesen mit `nc_get_var`
5. Datei schließen mit `nc_close`

Funktionsweise…

- Unterschiedliche Modi
  - Nach dem Anlegen im Define Mode
  - Nach dem Öffnen im Data Mode
- Bei NetCDF-4 automatischer Moduswechsel
  - Ansonsten `nc_redef` bzw. `nc_enddef` notwendig
- Data Mode erlaubt das Speichern von Daten

Funktionsweise…

- Define Mode erlaubt das Ändern der Dateistruktur
  - Hinzufügen von Dimensionen, Attributen und Variablen
- Einige Einstellungen nur direkt nach Definition änderbar
  - Unter anderem Kompression, Byte-Reihenfolge, Fehlerkorrektur und Füllwert

Parallel-NetCDF

- Alternativer Ansatz für parallele E/A
  - Unterstützt das klassische und 64-Bit-Formate
- Entwickelt durch Northwestern University und Argonne National Laboratory
  - Teilweise dieselben Entwickler wie MPI-IO und OrangeFS
- Schnittstelle ist inkompatibel
  - NetCDF-4 kann aber Parallel-NetCDF nutzen

Überblick

- Besteht aus Dateiformaten und Bibliotheken
  - Erlaubt Verwaltung selbstbeschreibender Daten
- Aktuelle Version ist HDF5
  - HDF4 wird immer noch aktiv unterstützt
- Probleme mit Vorversionen
  - Komplizierte API
  - Einschränkungen wie z. B. 32-Bit-Adressierung

Überblick

- Unterstützt Gruppen und Datensätze
  - Datensätze speichern Daten
  - Gruppen strukturieren den Namensraum
  - Analog zu Dateien und Verzeichnissen
- Gruppen können Datensätze und Gruppen enthalten
  - Hierarchischer Namensraum
- Attribute für Datensätze und Gruppen
  - Beispielsweise Minimum und Maximum

Überblick…

- Objekte werden über POSIX-ähnliche Pfade zugegriffen
  - Beispielsweise `/path/to/dataset`
  - Pfad kann Informationen über Daten enthalten
- HDF-Dateien sind selbstbeschreibend
  - Können ohne vorheriges Wissen über Struktur und Inhalt geöffnet und interpretiert werden

Überblick…

- Datensätze können mehrdimensionale Arrays eines Basisdatentypen speichern
  - Integer, Float, Character, Bitfield, Opaque, Enumeration, Reference, Array, Variable-length, Compound
- Datensätze haben Eigenschaften
  - Größe, Genauigkeit, Byte-Reihenfolge etc.
- Beliebig viele unbeschränkte Dimensionen

Sprachspezifische Datenspeicherung

- Sprachspezifische Datenspeicherung
  - Daten werden nach C-Konvention zeilenweise gespeichert
  - Fortran-Daten werden automatisch umgewandelt

1	2	3
4	5	6
7	8	9

Abbildung: 3x3-Matrix

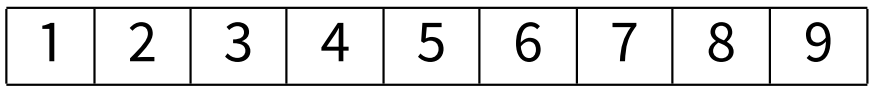

(a) C-Speicherlayout

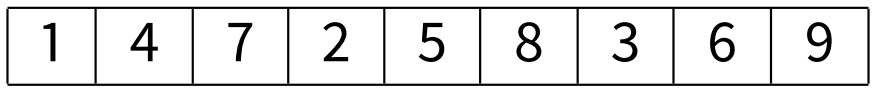

(b) Fortran-Speicherlayout

Chunking

- Chunking erlaubt Daten in allen Dimensionen zu erweitern
  - Bei zusammenhängender Speicherung nicht möglich
- Mögliche Optimierungen
  - Anpassung an Streifenbreite
  - Effizienter spaltenweiser Zugriff
- Zusatzaufwand
  - Üblicherweise geringere Leistung

Chunking…

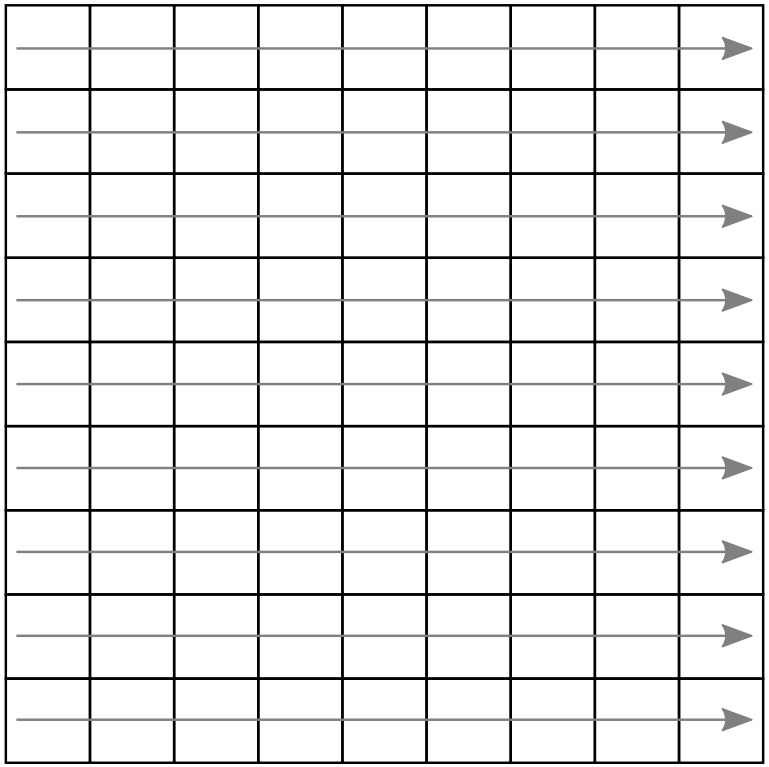

Abbildung: Zusammenhängender Datensatz

- Daten können nur in eine Dimension wachsen

Chunking…

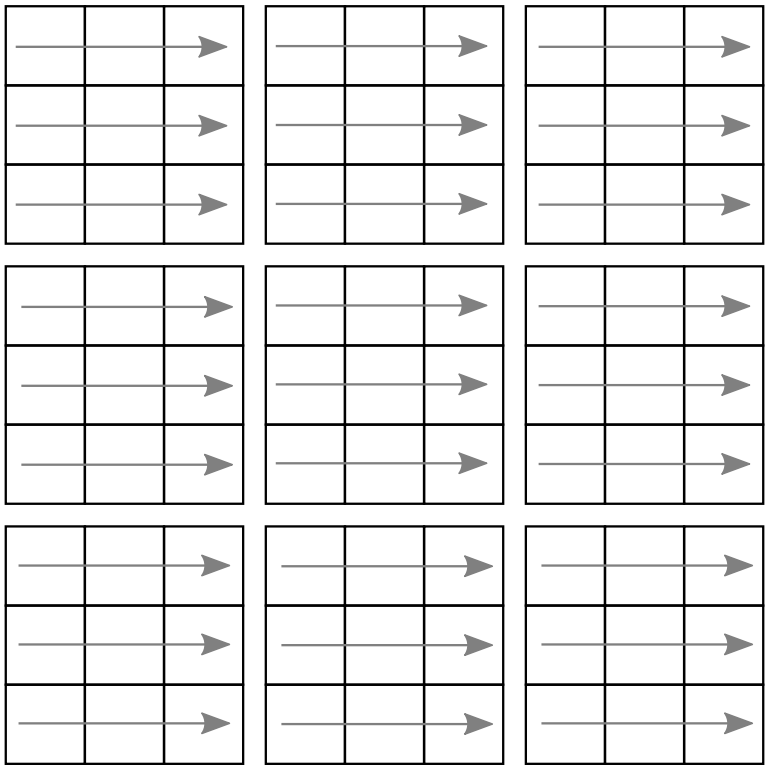

Abbildung: Datensatz mit Chunking

- Daten können in mehrere Dimensionen wachsen

Sonstiges

- Unterstützung für mehrere Backends
  - POSIX und MPI-IO
  - MPI-IO erlaubt parallelen Zugriff auf gemeinsame HDF-Dateien
- Diverse Werkzeuge verfügbar
  - Beispielsweise `h5dump` um Daten auszugeben
- Zusätzliche Funktionen
  - Transparente Kompression
  - Benutzerdefinierte Filter

Beispiel

```
1  HDF5 "..." {
2  GROUP "/" {
3     ATTRIBUTE "creation_date" {
4        DATATYPE  H5T_STRING {
5           STRSIZE H5T_VARIABLE;
6           STRPAD H5T_STR_NULLTERM;
7           CSET H5T_CSET_ASCII;
8           CTYPE H5T_C_S1;
9        }
10       DATASPACE  SIMPLE { ( 1 ) / ( 1 ) }
11    }
12 }
13 }
```

Listing 3: h5dump-Ausgabe

Überblick

- ADIOS ist stark abstrahiert
  - Kein byte- oder element-orientierter Zugriff
  - Direkte Unterstützung für Anwendungsdatenstrukturen
- Entworfen für hohe Leistung
  - Insbesondere von wissenschaftlichen Anwendungen
  - Caching, Zusammenfassen von Operationen etc.

Überblick…

- E/A-Konfiguration wird in XML-Datei ausgelagert
  - Beschreibt relevante Datenstrukturen
  - Wird benutzt um automatisch Code zu erzeugen
- Entwickler spezifizieren E/A auf hoher Abstraktionsstufe
  - Kein Kontakt mit Middleware oder Dateisystem
  - Änderungen ohne Neukompilation möglich

Beispiel

```
1 <adios-config host-language="C">
2   <adios-group name="checkpoint">
3     <var name="rows" type="integer"/>
4     <var name="columns" type="integer"/>
5     <var name="matrix" type="double"
          ↪ dimensions="rows,columns"/>
6   </adios-group>
7   <method group="checkpoint" method="MPI"/>
8   <buffer size-MB="100" allocate-time="now"/>
9 </adios-config>
```

Listing 4: ADIOS-XML-Konfiguration

- Daten werden in Gruppen zusammengefasst
- Pro Gruppe Festlegung der E/A-Methode
- Puffergrößen können gesetzt werden

Beispiel...

```
1 adios_open(&adios_fd, "checkpoint", "checkpoint.bp", "w",
      ↪ MPI_COMM_WORLD);
2 #include "gwrite_checkpoint.ch"
3 adios_close(adios_fd);
```

Listing 5: ADIOS-Code

- Code wird mit `gpp.py` generiert
  - `gread_checkpoint.ch` und `gwrite_checkpoint.ch`
- Entwickler müssen nur entsprechenden Header einbinden
  - Und ein wenig auf Variablennamen etc. achten

Beispiel...

```
1 adios_groupsize = 4 \
2                   + 4 \
3                   + 8 * (rows) * (columns);
4 adios_group_size (adios_handle, adios_groupsize,
      ↪ &adios_totalsize);
5 adios_write (adios_handle, "rows", &rows);
6 adios_write (adios_handle, "columns", &columns);
7 adios_write (adios_handle, "matrix", matrix);
```

Listing 6: ADIOS-Header für das Schreiben

- Gruppengröße wird automatisch berechnet und gesetzt
- `adios_write`-Aufrufe schreiben Daten
  - Schreibvorgänge werden möglichst im Cache abgewickelt

Beispiel…

```
1 s = adios_selection_writeblock (rank);
2 adios_schedule_read (fp, s, "matrix", 1, 1, matrix);
3 adios_perform_reads (fp, 1);
4 adios_selection_delete (s);
```

Listing 7: ADIOS-Header für das Lesen

- Lesen komplexer als Schreiben
  - Bietet aber auch zusätzliche Funktionalität
- Ausschnitte der Daten können selektiert werden
  - ADIOS bestimmt selbstständig optimale Lesestrategie
- Mehrere Leseoperationen können geplant werden
  - Spezifizierung von Schritten
  - Anschließend eigentliche Ausführung

Funktionalität

- Eigenes Dateiformat (BP)
  - Kann in HDF5, NetCDF und ASCII konvertiert werden
- Unterstützt Datentransformationen
  - Unter anderem Kompression
- Read-Scheduling für effiziente Ausführung
  - Erlaubt beispielsweise Staging von Daten
- Zusätzliche Funktionalität
  - `adios_{start,stop}_calculation`: E/A sollte parallel zur Berechnung ausgeführt werden
  - `adios_end_iteration`: Stellt Timinginformationen bereit

Interaktion

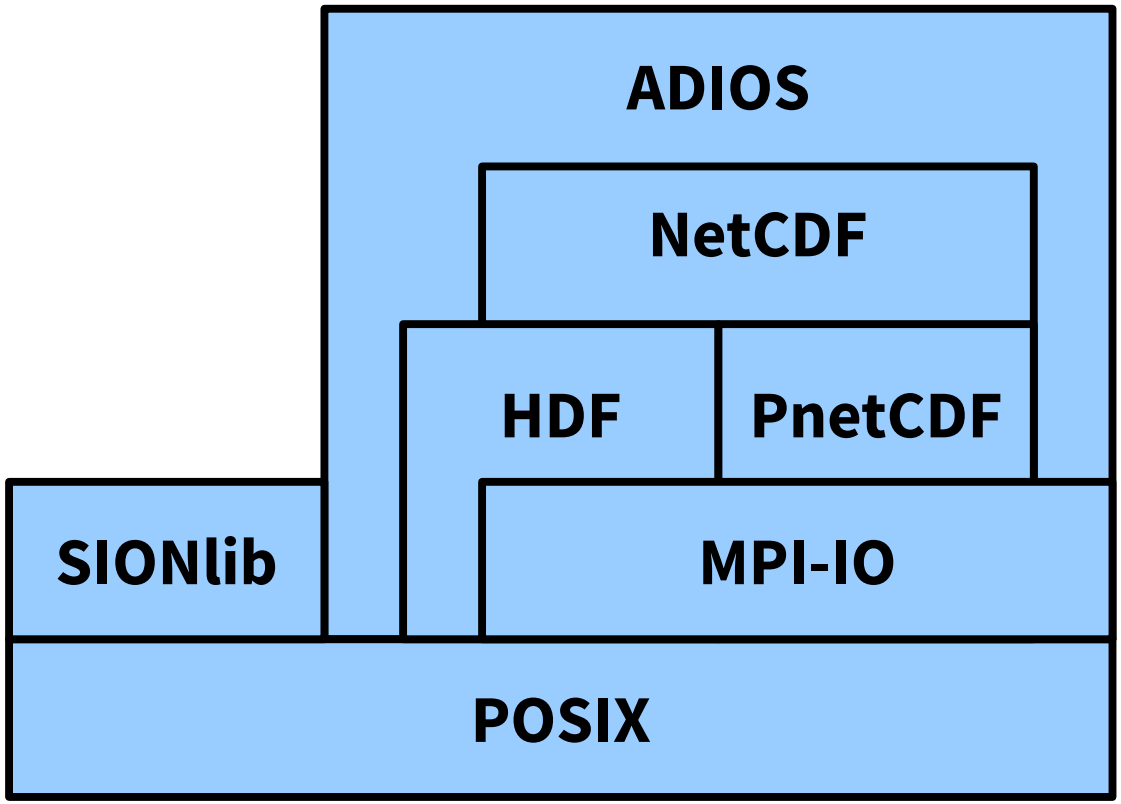

Abbildung: Interaktion zwischen Bibliotheken

Disjoint [1]

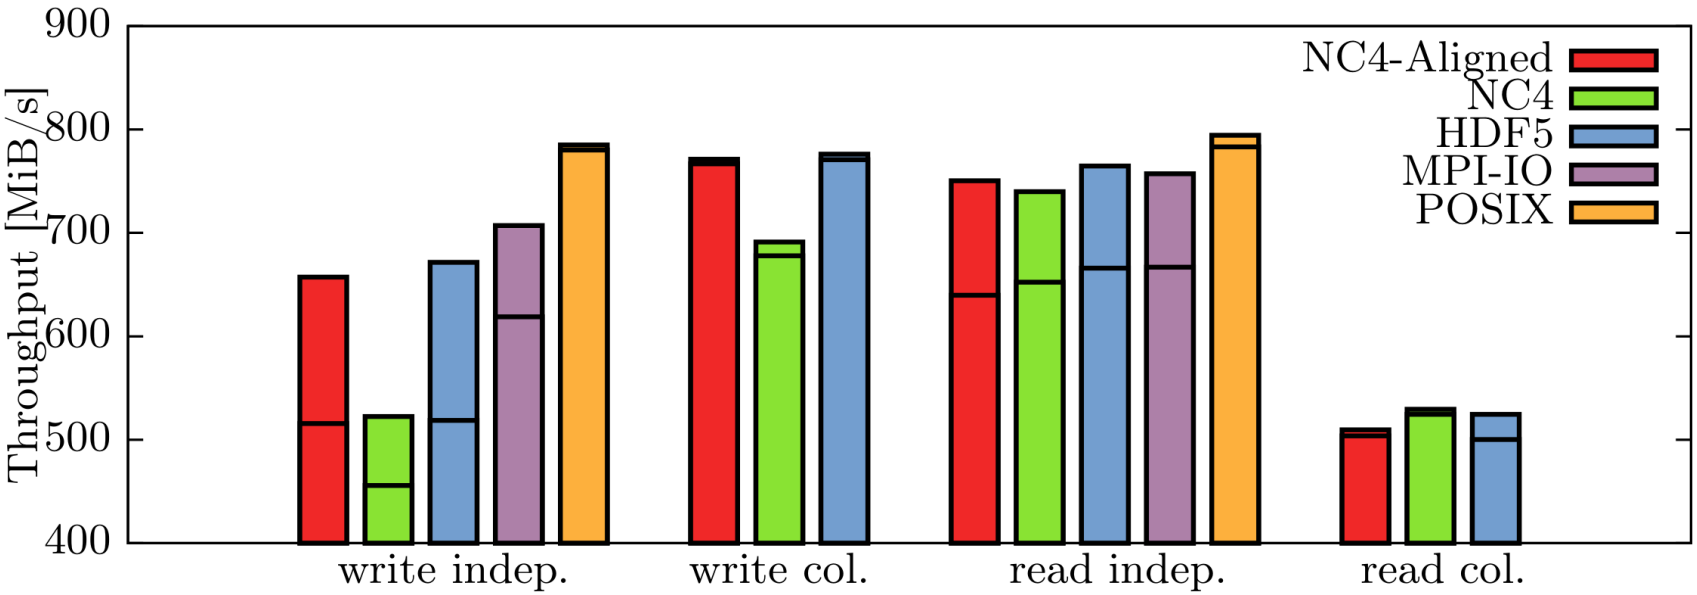

Fig. 5. Disjoint Pattern

- Clients für zusammenhängende Datenblöcke verantwortlich
- Keine Überlappungen
- Jeder Client kommuniziert potentiell mit allen Servern

1-OST [1]

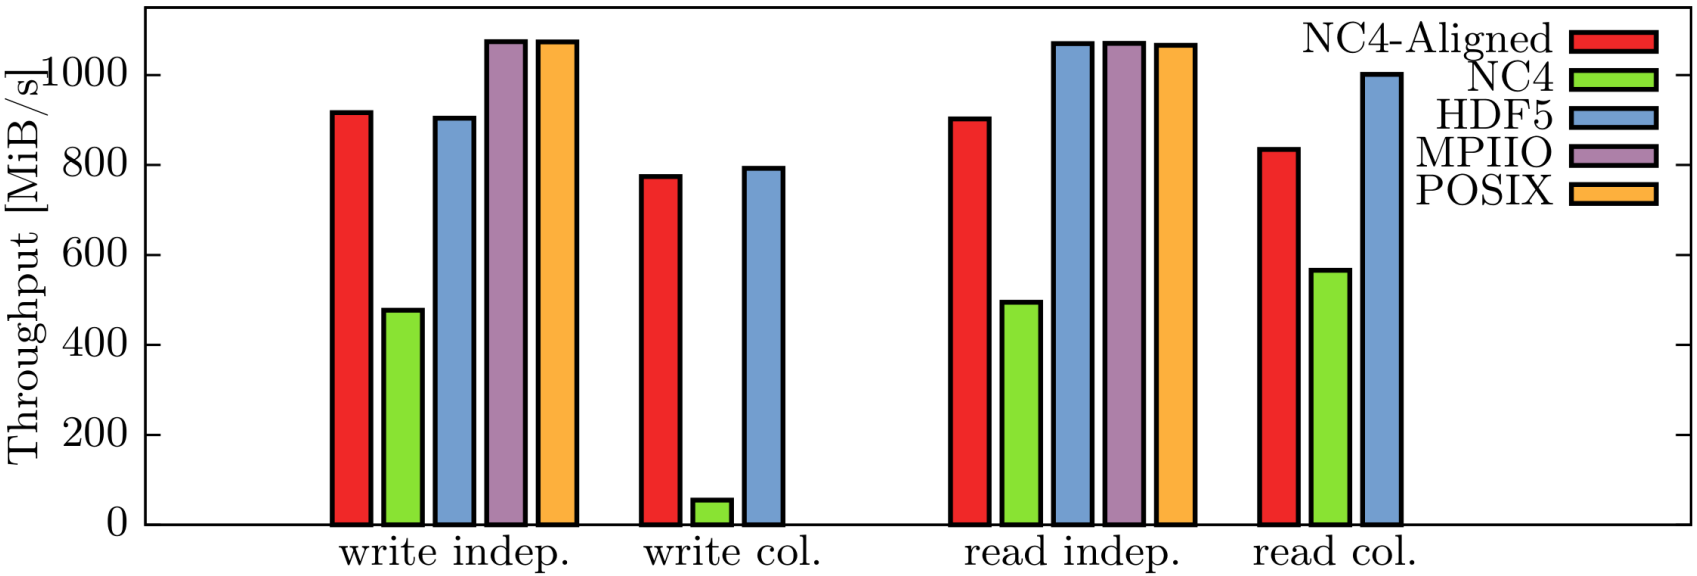

Fig. 6. 1-OST Pattern

- Jeder Client kommuniziert mit genau einem Server

Transfer-/Chunk-Größen [1]

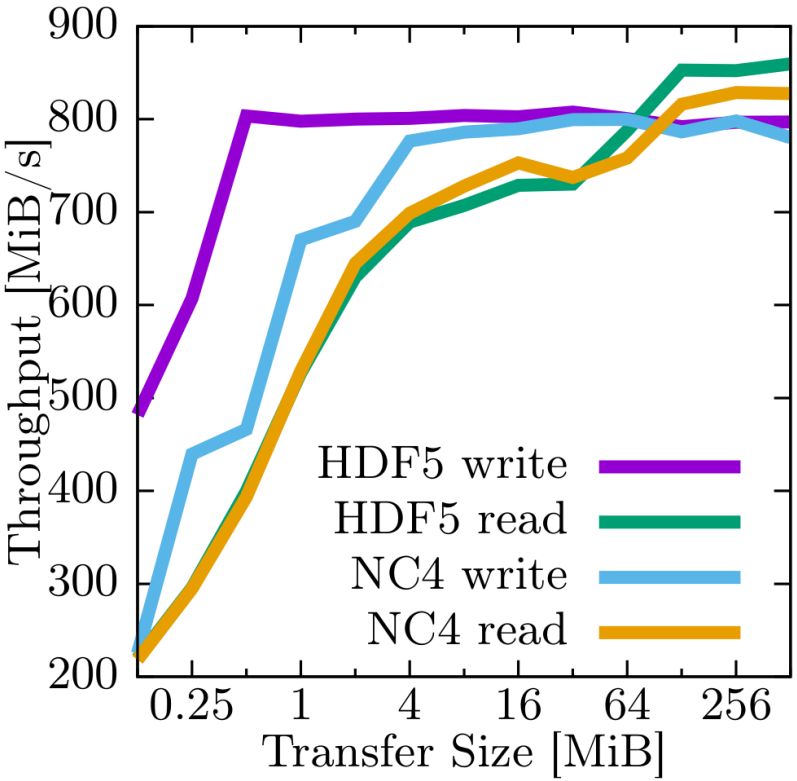

Fig. 7. Varying Transfer Size

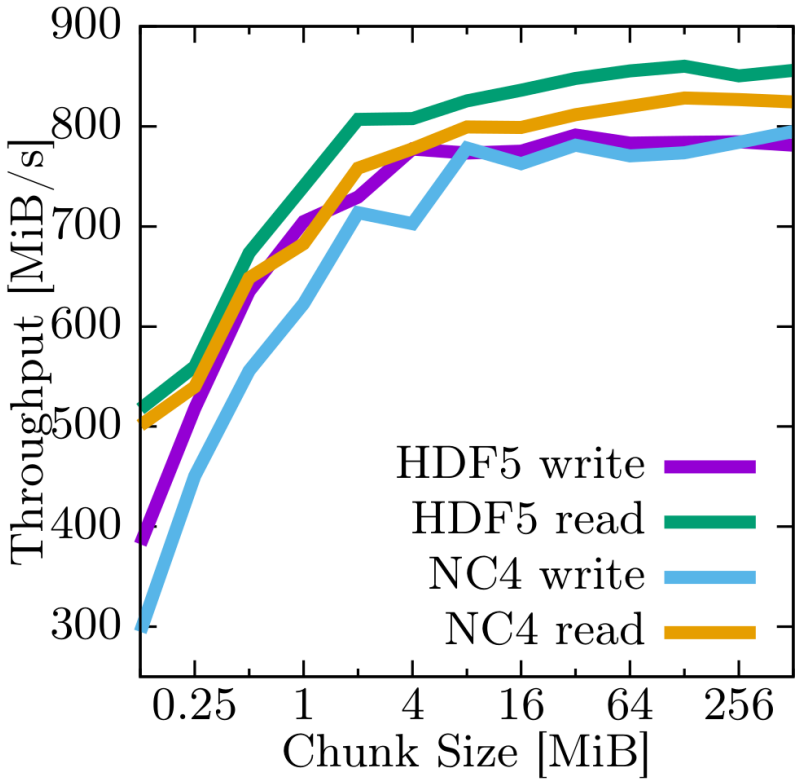

Fig. 8. Chunked Layout

1- bis 10-OST [1]

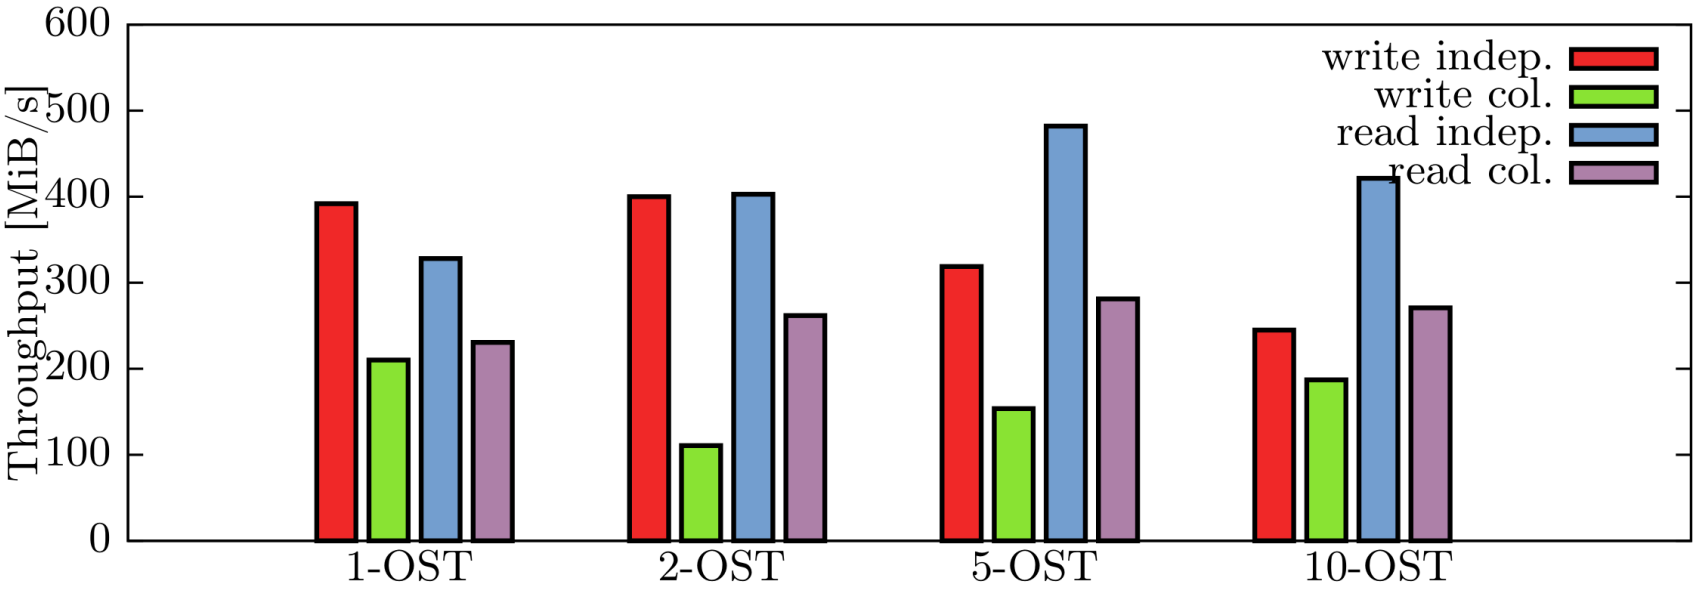

Fig. 9. 1- to 10-OST Pattern, HDF5 with Chunked I/O

Leistungsbewertung

- Interaktion zwischen Bibliotheken ist komplex
  - Erreichbare Leistung kann nicht einfach vorhergesagt werden
  - Mögliche Leistungsprobleme auf mehreren Schichten
  - Messung schwierig, da alle Schichten erfasst werden müssen
- Optimierung für vorhandenes System notwendig
  - HDF5 und SIONlib erlauben Anpassung an Dateisystemgrenzen
  - NetCDF hat dafür momentan keine Unterstützung

Zusammenfassung

- E/A-Bibliotheken erlauben strukturierten Zugriff
  - Zusätzliche Annotationen und Metadaten erlauben einfachen Austausch
- Zoo von Bibliotheken für unterschiedliche Anwendungszwecke
  - Analyse von Fehlern und Leistungsproblemen schwierig
  - SIONlib umgeht Leistungsprobleme aktueller Dateisysteme
- NetCDF und HDF bieten ähnliche Funktionalität
  - Beide erlauben parallele E/A

Quellen I

[1] Christopher Bartz, Konstantinos Chasapis, Michael Kuhn, Petra Nerge, and Thomas Ludwig. A Best Practice Analysis of HDF5 and NetCDF-4 Using Lustre. In Julian Martin Kunkel and Thomas Ludwig, editors, *High Performance Computing*, number 9137 in Lecture Notes in Computer Science, pages 274–281, Switzerland, 06 2015. Springer International Publishing.

[2] SIONlib. File Format. `https://apps.fz-juelich.de/jsc/sionlib/docu/fileformat_page.html`.