



## Buch: Softwareentwicklung für die Naturwissenschaften

Dr. habil. Till Biskup

— Glossar zu Kapitel 31: „Datenverarbeitung und -Analyse: selbstdokumentierend“ —

---

*Hinweis: Die nachfolgend genannten Begriffe und Definitionen erheben keinen Anspruch auf formale Korrektheit, sondern dienen lediglich dem besseren Verständnis der in der Vorlesung behandelten Themen und sind im jeweiligen Kontext zu sehen. Mehrfache, voneinander abweichende Definitionen in unterschiedlichen Kontexten sind daher möglich. Englische Begriffe werden zwar nach Möglichkeit übersetzt, erscheinen aber ggf. unter ihrem englischen Namen in der Liste. Verweise untereinander sind durch ↑ gekennzeichnet.*

**abstrakte Klasse** ↑Klasse, die zunächst einmal nur eine ↑Schnittstelle liefert und nur (abstrakte) ↑Methoden ohne Implementierung enthält.

**abstrakte Schnittstelle** *abstract interface*, ↑abstrakte Klasse, die in Sprachen, die keine ↑Mehrfachvererbung unterstützen, explizit als ↑Schnittstelle (*interface*) definiert wird, so dass eine Klasse von mehreren abstrakten Schnittstellen „erben“ kann.

**Abstraktion** Nach Edsger Dijkstra [1] das einzige mentale Werkzeug, das es erlaubt, eine große Vielzahl von Fällen abzudecken. Zweck der Abstraktion ist es nicht, vage zu sein, sondern im Gegenteil ein neues Bedeutungsniveau zu schaffen, das präzise Beschreibungen erlaubt.

**Abstraktionsebene** Summe aller ↑Abstraktionen eines bestimmten Abstraktionsgrades.

**ANSI** *American National Standards Institute*, private, gemeinnützige, amerikanische Organisation zur Koordinierung der Entwicklung freiwilliger Normen in den U.S.A.

**Arbeitskopie** Lokale Kopie eines Zustandes eines ↑Repositorys, auf der gearbeitet (entwickelt) bzw. die produktiv eingesetzt wird.

**assoziatives Datenfeld** *map, dictionary* oder *associative array*, Datenstruktur, die – anders als ein gewöhnliches Feld (*array*) bzw. eine Liste (*list*) – nichtnumerische (oder nicht fortlaufende) Schlüssel (zumeist Zeichenketten)

verwendet, um die enthaltenen Elemente zu adressieren. Die Elemente sind (meist) in keiner festgelegten Reihenfolge abgespeichert. Idealerweise werden die Schlüssel so gewählt, dass eine für die Programmierer nachvollziehbare Verbindung zwischen Schlüssel und Datenwert besteht (↑semantisches Verständnis).

**Attribut** im Kontext der ↑objektorientierten Programmierung eine Variable, die innerhalb einer ↑Klasse definiert wird. ↑Methoden operieren auf den Attributen einer ↑Klasse bzw. dem daraus erzeugten ↑Objekt.

**Auszeichnungssprache** *markup language* (ML) maschinenlesbare Sprache für die Gliederung und Formatierung von Texten und anderen Daten. Der bekannteste Vertreter ist die *Hypertext Markup Language* (↑HTML), die Kernsprache des World Wide Webs.

**Clean Code** „sauberer Code“, letztlich lesbarer Code, der insbesondere im Kontext der naturwissenschaftlichen Datenauswertung die essentiellen Kriterien von Wiederverwendbarkeit, Zuverlässigkeit und Überprüfbarkeit erfüllt.

**commit** Übertragen einer Version (↑Revision) in das ↑Repository.

**CSV** *comma-separated values*, ↑Datenformat für zeilenweise Speicherung zusammengehöriger Daten, ähnlich der Zeilen in einer Tabelle. Die einzelnen Felder in einer Zeile werden oft durch Komma (daher der Name), ggf.

aber auch durch Semikolon getrennt. Im Gegensatz zu ↑DSV wurde CSV nie standardisiert, weshalb es Tabellenkalkulationen großer Hersteller gibt, die zwar CSV exportieren, aber den eigenen Export nicht mehr importieren können. Insbesondere der Umgang mit Feldtrennern innerhalb eines Feldes ist nicht festgelegt.

**Datenformat** digitales Speicherformat für Daten jeglicher Form. Grundsätzlich werden binäre und Textformate unterschieden. Während erstere meist mit deutlich geringerem Speicherbedarf auskommen, sind sie im Gegensatz zu letzteren nicht ohne Hilfsmittel lesbar. Textformate hingegen sind, ein beliebiger Texteditor vorausgesetzt, prinzipiell menschenlesbar. Wichtige Vertreter binärer Datenformate in den Naturwissenschaften sind ↑HDF5 und ↑IEEE 754 (eigentlich ein Standard für die Darstellung von Gleitkommazahlen). Wichtige Vertreter von Textformaten sind ↑CSV, ↑DSV, ↑JSON, ↑Windows-INI, ↑XML und ↑YAML.

**Datensatz** Einheit aus (numerischen) Daten und Informationen über die Daten (↑Metadaten).

**Domain-Driven Design** Ein gutes ↑Modell der komplexen Realität und Fragestellung bildet die Grundlage für den ↑Kern einer Anwendung.

**DSV** *delimiter-separated values*, ↑Datenformat für zeilenweise Speicherung zusammengehöriger Daten, ähnlich der Zeilen in einer Tabelle. Im Gegensatz zu ↑CSV ist das Format eindeutig definiert. Das Trennzeichen (*delimiter*) ist beliebig wählbar. Sollte es innerhalb eines Feldes auftauchen, wird es durch Backslash („\“) geschützt.

**Eindeutigkeit** Bijektivität, Eindeutigkeit in beiden Richtungen. Mathematisch die Abbildung eines Elements einer Menge auf genau ein Element einer zweiten Menge und umgekehrt, weshalb Definitions- und Zielmenge die gleiche Mächtigkeit aufweisen. Im Kontext von ↑Versionsnummern die Eindeutigkeit der Zuordnung einer Versionsnummer zu *genau einem* Zustand der Software und umgekehrt der

Zuordnung eines Zustandes der Software zu *genau einer* Versionsnummer. Im Kontext von Namen bedeutet das: Jeder Name bildet auf *genau ein* Konzept ab, so dass man eindeutig vom Namen auf das dahinterstehende Konzept und vom Konzept eindeutig auf den Namen schließen kann.

**Entwicklerversion** Eine ↑Arbeitskopie der Software, an der aktiv entwickelt wird und die im Gegensatz zu ↑Produktivversionen *nicht* für den produktiven Einsatz gedacht ist. Entwicklerversionen sollten entsprechend (z.B. im Versionsnummernschema) klar gekennzeichnet werden. Ein Problem solcher Entwicklerversionen und gleichzeitig der Grund, warum sie *nie* produktiv für (bleibende) Datenauswertung verwendet werden sollten, ist der, dass die ↑Eindeutigkeit zwischen ↑Versionsnummer und Zustand der Software nicht gewährleistet werden kann, da die Versionsnummer frühestens beim nächsten ↑commit inkrementiert wird, die Software aber zwischendurch ggf. aktiv verändert und weiterentwickelt.

**Funktion** im Kontext der ↑strukturierten Programmierung eine Liste von Anweisungen, die eine bestimmte Aufgabe erfüllt und der Programmiersprache unter einem festen Namen bekannt ist. Vgl. ↑Methode.

**generische Routine** Funktionalität (als ↑Funktion oder ↑Klasse implementiert), die eine ↑abstrakte Schnittstelle implementiert und so modular die Verarbeitung unterschiedlicher Inhalte ermöglicht. Lässt sich mit etwas Mühe auch ↑strukturiert implementieren. Die ↑objektorientierte Programmierung spielt hier aber über ↑Vererbung und ↑Polymorphie ihre Stärken aus.

**größeres Projekt** hier: Alles, was mehr als zwei Wochen Arbeit kostet und deutlich mehr als zweihundert Zeilen (reinen) Quellcode bzw. mehr als eine Handvoll Unterfunktionen umfasst. Wichtig ist der Fokus: Sobald ein Programm über längere Zeit und/oder von anderen verwendet werden soll (was eher die Regel statt die Ausnahme ist), ist es ein größeres

Projekt.

**GUI** *graphical user interface*, grafische ↑Nutzerschnittstelle

**HDF5** *Hierarchical Data Format*, ↑Datenformat, das insbesondere in wissenschaftlichen Anwendungen für die Speicherung großer Datenmengen verwendet wird. Optimierte Strukturen und Algorithmen erlauben das effiziente Speichern und Auslesen von ein- und mehrdimensionalen Tabellen, ohne dass jeweils der komplette Inhalt der Datei in den Speicher geladen werden muss. Tabellen und andere Daten können in ein und derselben Datei in einer beliebigen Verzeichnisstruktur abgelegt werden. Das ermöglicht u.a. die gleichzeitige Speicherung von Messwerten und zugehörigen ↑Metadaten. Das Format wurde vom *National Center for Supercomputing Applications* (NCSA) entwickelt und wird u.a. von der NASA für Missionen verwendet.

**Historie** hier: geordnete Liste der ↑Parametersätze aller Verarbeitungsschritte eines ↑Datensatzes. Zwingende Voraussetzung für ↑reproduzierbare Wissenschaft im Kontext des Einsatzes eines ↑Systems zur Datenverarbeitung.

**HTML** *Hypertext Markup Language*, textbasierte ↑Auszeichnungssprache zur Strukturierung elektronischer Dokumente wie Texte mit Hyperlinks, Bildern und anderen Inhalten. HTML-Dokumente sind die Grundlage des World Wide Web und werden von Webbrowsern dargestellt. Neben den vom Browser angezeigten Inhalten können HTML-Dateien zusätzliche Angaben in Form von Metainformationen enthalten, z. B. über die im Text verwendeten Sprachen, den Autor oder den zusammengefassten Inhalt des Textes.

**IEEE** *Institute of Electrical and Electronics Engineers*, weltweiter Berufsverband von Ingenieuren hauptsächlich aus den Bereichen Elektrotechnik und Informationstechnik. Der Verband veranstaltet Fachtagungen, gibt diverse Fachzeitschriften heraus und bildet Gremien für die Standardisierung von Techniken, Hardware und Software.

**IEEE 754** Norm des ↑IEEE, die die Standarddarstellungen für binäre Gleitkommazahlen in Computern definiert und genaue Verfahren für die Durchführung mathematischer Operationen, insbesondere für Rundungen, festlegt. In der Fassung ↑ANSI/IEEE 754-1985 ist nur der Standard für 64 Bit eindeutig.

**Infrastruktur** personelle, sachliche und finanzielle Ausstattung, um ein angestrebtes Ziel zu erreichen. Im Kontext der Softwareentwicklung die Gesamtheit der Hilfsmittel, die (manche) Abläufe formalisieren und für Struktur und Überprüfbarkeit sorgen. Erleichtert die Arbeit des Programmierers, indem sie viele Aspekte festlegt, die so zur Routine werden (und keine Denkleistung absorbieren).

**Instanvariable** Variable (↑Attribut) eines ↑Objektes, die entsprechend in einer ↑Klasse definiert wird und aus allen ↑Methoden der Klasse heraus erreichbar ist.

**Iteration** eine von zwei Kontrollstrukturen der ↑strukturierten Programmierung, neben der ↑Selektion. Meist als Schleife implementiert, die über alle Elemente einer Liste läuft und für jedes Element bestimmte Anweisungen ausführt.

**JSON** *JavaScript Object Notation*, hierarchisches ↑Datenformat, das ursprünglich zur einfachen Persistierung (↑Persistenz) von JavaScript-Objekten entwickelt wurde. Heute erfreut es sich als Austauschformat für Objekte und Datenstrukturen großer Beliebtheit, wird aber gerade für die Ablage von Konfigurationen in menschenlesbaren (und schreibbaren) Dateien aufgrund dessen noch einfacherer und übersichtlicherer Syntax zunehmend von ↑YAML abgelöst.

**Kapselung** *encapsulation*, ein ↑Objekt enthält Daten (↑Attribute) und zugehöriges Verhalten (↑Methoden) und kann beides nach Belieben vor anderen Objekten verstecken.

**Kern der Anwendung** Implementation des zugrundeliegenden ↑Modells in Software, d.h. Abbildung auf Code, zumeist in Form abstrakter ↑Klassen. Vgl. ↑Domain-Driven Design.

**Klasse** *class*, im Kontext der ↑objektorientierten Programmierung die Blaupause für die Erzeugung eines ↑Objektes; Definition der Daten (↑Attribute) und des zugehörigen Verhaltens (↑Methoden).

**Lösungsraum** *solution domain*, Kontext der Programmierer eines Programms, Gegensatz zum ↑Problemraum. Namen aus dem Lösungsraum bestehen i.d.R. aus Begriffen aus der Welt der Programmierung.

**Mehrfachvererbung** *multiple inheritance*, eine ↑Klasse erbt (↑Vererbung) von mehr als einer ↑Superklasse. Wird von den wenigsten Programmiersprachen unterstützt, oftmals behilft man sich hier aber des Konzeptes einer ↑Schnittstelle (*interface*) (3.) und kann dann mehr als eine solche implementieren (bzw. davon erben). Konzeptionell lassen sich diese beiden Ansätze quasi identisch einsetzen.

**Metadaten** Informationen zu den numerischen Daten, notwendige Voraussetzung für eine sinnvolle Verarbeitung der Daten im Kontext eines ↑Systems zur Datenverarbeitung und für ↑reproduzierbare Wissenschaft.

**Methode** im Kontext der ↑objektorientierten Programmierung eine ↑Funktion, die innerhalb einer ↑Klasse definiert wird und auf den ↑Attributen einer ↑Klasse bzw. dem daraus erzeugten ↑Objekt operiert.

**Modell** sprachliche Formulierung des ↑Problemraums und seiner entscheidenden Zusammenhänge und Abläufe auf hohem Abstraktionsniveau; Summe der „Geschäftsregeln“

**Modularisierung** Aufteilung der Gesamtaufgabe in kleinere Abschnitte. Die Aufteilung wird so lange fortgesetzt, bis die Lösung für den aktuellen Abschnitt unmittelbar in Form von Quellcode offensichtlich ist. Setzt die Definition von ↑Schnittstellen voraus.

**monolithisch** aus einem Stück bestehend; zusammenhängend und fugenlos

**Nutzerschnittstelle** *user interface* (UI), ↑Schnittstelle zwischen Nutzer und Programm, meist

auf hoher ↑Abstraktionsebene. Nutzerschnittstellen verstecken für gewöhnlich die Implementierung und internen Abläufe einer Anwendung vor dem Nutzer. Typische Beispiele sind heute weit verbreitete grafische Oberflächen (*graphical user interface* GUI). Es gibt aber auch textbasierte (interaktive) Nutzerschnittstellen (*commandline interface*, CLI).

**Objekt** *object*, im Kontext der ↑objektorientierten Programmierung der grundlegende Baustein eines Programms, bestehend aus den Daten (↑Attribute) und dem zugehörigen Verhalten (↑Methoden). Ein Objekt ist in diesem Kontext immer die Instanz einer ↑Klasse.

**objektorientiert** dem ↑Paradigma der ↑objektorientierten Programmierung folgend

**objektorientierte Programmierung** (OOP) ein ↑Programmierparadigma, bei dem Daten (Variablen zugewiesene Werte, als ↑Attribute bezeichnet) und Funktionen (↑Methoden), die auf diesen Daten (Attributen) operieren, eine Einheit bilden. Die in den ↑Attributen gespeicherten Daten lassen sich i.d.R. nur vermittelt durch (öffentlich zugängliche) ↑Methoden der ↑Klasse bzw. des daraus erzeugten ↑Objektes ansprechen. Es gibt eine klare Trennung zwischen öffentlicher ↑Schnittstelle und internen Verarbeitungsroutinen. Wichtige Vertreter objektorientierter Programmiersprachen sind Smalltalk, C++ und Java, aber auch Python.

**Paradigma** nach Thomas S. Kuhn [2] ein Satz allgemein anerkannter wissenschaftlicher Leistungen, der für eine gewisse Zeit einer Gemeinschaft von Fachleuten maßgebende Probleme und Lösungen liefert

**Parametersatz** Gesamtzahl der Parameter, die eine Routine zur Datenverarbeitung zur Durchführung ihrer Aufgabe benötigt. Dazu gehören sowohl die expliziten (vom Nutzer angegebenen) als auch die impliziten (vordefinierten und deshalb optionalen) Parameter. Im Kontext eines ↑Systems zur Datenverarbeitung gehört zu einem vollständigen Parametersatz noch die ↑Versionsnummer der Routi-

ne, Datum und Uhrzeit, der Name des Durchführenden und die verwendete ↑Plattform.

**Persistenz** Fähigkeit, Daten (oder ↑Objekte) oder logische Verbindungen über lange Zeit (insbesondere über einen Programmabbruch hinaus) bereitzuhalten; benötigt ein nichtflüchtiges Speichermedium.

**Plattform** Zusammenspiel aus Betriebssystem und Hardware-Architektur. Betriebssysteme können bis zu einem gewissen Grad unterschiedliche Hardware-Architekturen abstrahieren, so dass der gleiche Binärcode auf unterschiedlicher Hardware lauffähig ist, ohne neu kompiliert werden zu müssen.

**plattformunabhängig** Unabhängigkeit von einer spezifischen ↑Plattform. Neben Software sollten insbesondere ↑Datenformate plattformunabhängig sein, da nur so ein dauerhafter und unabhängiger Zugriff gewährleistet werden kann. Plattformunabhängigkeit hat sowohl eine Hardware- und Betriebssystemarchitektur als auch eine zeitliche Komponente. Alle drei großen Desktop-Betriebssysteme (Windows, Linux, macOS) sind in den Naturwissenschaften relativ weit verbreitet. Darüber hinaus findet die Entwicklung von Betriebssystemen auf der Zeitskala einer Archivierung schnell statt.

**Polymorphie** *polymorphism*, „Vielgestaltigkeit“, ähnliche ↑Objekte können auf die gleiche Botschaft (den Aufruf einer gleichnamigen ↑Methode) in unterschiedlicher Weise reagieren.

**Problemraum** *problem domain*, Kontext der Fragestellung, die mit einem Programm (d.h. Software) angegangen werden soll, Gegensatz zum ↑Lösungsraum. Namen aus dem Problemraum verweisen i.d.R. auf Konzepte und ↑Abstraktionen, mit denen die Anwender eines Programms vertraut sind (aber nicht notwendigerweise die Programmierer/Entwickler).

**Produktivversion** Im Gegensatz zur ↑Entwicklerversion eine für den Produktiveinsatz geeignete ↑Revision eines Programms. Sie zeichnet sich u.a. durch eine eindeutige Versionsnummer aus (d.h. die Versionsnummer entspricht genau einem Zustand des Programms

und umgekehrt ein Zustand des Programms genau einer Versionsnummer).

**Programmierparadigma** ein ↑Paradigma der Art zu programmieren. Wichtige Beispiele sind ↑strukturierte Programmierung, ↑objektorientierte Programmierung und funktionale Programmierung.

**Prozessorarchitektur** Architektur des (Haupt-) Prozessors eines Rechners. Oft kritisches Detail für die konkrete Verarbeitung von Anweisungen. Sollte deshalb Teil eines vollständigen ↑Parametersatzes sein.

**Replizierbarkeit** *replicability*, unabhängige Wiederholung der (Roh-)Datenerhebung, meist in Form von Experimenten und Beobachtungen, entsprechend nicht in jedem Fall durchführbar. Vgl. ↑Reproduzierbarkeit.

**Repository** Versionsdatenbank, (zentraler) Speicherort der versionierten Dateien im Kontext einer ↑Versionsverwaltung.

**reproduzierbare Wissenschaft** *reproducible science*, seit der Etablierung rechnergestützter Datenauswertung eigentlich nie mehr erreichter, aber für die Wissenschaft konstituierender Aspekt, dass sich Ergebnisse und Auswertungen unabhängig reproduzieren lassen, weil alle dazu notwendigen Aspekte vollständig und ausreichend beschrieben wurden. Motivation für die Vorlesung, deren Ziel es ist, die Hörer mit Konzepten vertraut zu machen, die letztlich eine ernstzunehmende reproduzierbare Wissenschaft ermöglichen.

**Reproduzierbarkeit** *reproducibility*, vollständige Wiederholbarkeit einer beschriebenen Datenverarbeitung und -Analyse. Ausgangspunkt sind existierende Daten, entsprechend sollte sie in jedem Fall möglich sein. Vgl. ↑Replizierbarkeit.

**Revision** einzelner der ↑Versionsverwaltung bekannter Zustand eines ↑Repositorys

**Schnittstelle** *interface*, Begriff mit mehreren leicht unterschiedlichen Bedeutungen; (1.) ↑Signatur einer ↑Funktion oder ↑Methode. (2.) Im weiteren Sinne die Gesamtheit der öffentlichen ↑Attribute und ↑Methoden einer

↑Klasse bzw. eines ↑Objekts. Der Nutzer kennt nur die Schnittstelle, die Implementierung ist irrelevant und kann sich problemlos jederzeit ändern, solange die Funktionalität erhalten bleibt. Das dient der Trennung von Verantwortlichkeiten und ermöglicht ↑Modularisierung und ist in der Folge ein wesentlicher Aspekt der ↑Softwarearchitektur. (3.) In einer weiteren Bedeutung wird der Begriff (auch im Deutschen dann häufig mit seinem englischen Pendant) für (abstrakte) Klassen verwendet, die lediglich eine Schnittstelle (im Sinne von 2.) definieren. Das ist hauptsächlich dann von Bedeutung, wenn die Programmiersprache keine ↑Mehrfachvererbung unterstützt, aber das Implementieren von „*Interfaces*“.

**selbstdokumentierend** mehrere Bedeutungen, (1) Eigenschaft von Auswertungssoftware, alle Prozessierungsschritte (automatisch) zu dokumentieren. Wesentliche Voraussetzung für die Nachvollziehbarkeit wissenschaftlicher Datenverarbeitung und -Auswertung und damit für deren Wissenschaftlichkeit und in der Folge ↑reproduzierbarer Wissenschaft. (2) Quellcode, der u.a. durch geschickte Wahl der Namen von Variablen, Funktionen, Methoden, Objekten, Klassen, ... weitgehend ohne Kommentare lesbar und nachvollziehbar ist. Letztlich der „heilige Gral“ der Programmierung und Ziel sauberen Quellcodes (↑Clean Code).

**Selektion** eine von zwei Kontrollstrukturen der ↑strukturierten Programmierung, neben der ↑Iteration. In den meisten Sprachen über Bedingungen (`if...else...end`) realisiert, die sich ggf. beliebig verschachteln lassen.

**Semantik** 1. Bedeutung bzw. Inhalt eines Wortes, Satzes oder Textes; 2. Teilgebiet der Linguistik, dessen Untersuchungsobjekt die Bedeutung sprachlicher Zeichen und Zeichenfolgen ist.

**semantische Information** Bedeutungsebene einer Information (vgl. ↑Semantik).

**semantisches Verständnis** Verständnis der ↑semantischen Information, also der Bedeutung

bzw. des Inhaltes. Im Kontext von Auswertungsroutinen kann durch aussagekräftige Namensgebung der Schlüssel (Felder) eines ↑assoziativen Datenfeldes, in dem die ↑Metadaten abgelegt sind, eine entsprechende Ausdruckstärke des Quellcodes erreicht werden. Außerdem „weiß“ die Auswertungsroutine dann immer, was sich in einem gewissen Feld verbirgt (z.B. Größe und Einheit für die Achsenbeschriftung).

**Serialisierung** in der Informatik eine Abbildung von strukturierten Daten auf eine sequenzielle Darstellungsform. Serialisierung wird hauptsächlich für die Persistierung von Objekten in Dateien und für die Übertragung von Objekten über das Netzwerk bei verteilten Softwaresystemen verwendet.

**Signatur** hier: Name und Parameter einer ↑Funktion bzw. ↑Methode, also alles, was ein Nutzer braucht, um diese Funktion oder Methode verwenden zu können.

**Softwarearchitektur** Aufteilung eines größeren Projektes in einzelne kleinere Projekte bzw. Aufgaben (↑Modularisierung), Definition klarer ↑Schnittstellen und Anforderungen sowie der Interaktion der einzelnen Teile miteinander. Nach Robert C. Martin die Gestalt eines Systems, die ihm von seinen Entwicklern gegeben wird: Unterteilung des Systems in Komponenten, ihre Anordnung, und die Art ihrer Interaktion miteinander. [3, S. 136]

**strukturiert** dem ↑Paradigma der ↑strukturierten Programmierung folgend

**strukturierte Programmierung** ein ↑Programmierparadigma, das die Zahl möglicher Kontrollstrukturen auf nur zwei (↑Iteration, ↑Selektion) beschränkt, insbesondere den goto-Befehl eliminiert (E. Dijkstra). Idealerweise hat ein Codeblock nur jeweils genau einen Ein- und Ausgang. Nach D. Knuth der systematische Einsatz von ↑Abstraktion, der es ermöglicht, große Programme aus kleine(re)n Komponenten zusammensetzen. Wichtige frühe Vertreter strukturierter Programmiersprachen sind C und Pascal. Die meisten heutigen Programmiersprachen (mit Ausnahme

der funktionalen Programmiersprachen) unterstützen die strukturierte Programmierung.

**Subklasse** ↑Klasse, die von einer anderen Klasse (der ↑Superklasse) ↑Attribute und ↑Methoden erbt. Die ↑Vererbung geht dabei i.d.R. über die nach außen hin sichtbare ↑Schnittstelle der Superklasse hinaus. Die Subklasse erbt von der ↑Superklasse häufig nur den „kleinsten gemeinsamen Nenner“ und implementiert die spezifische Funktionalität.

**Superklasse** ↑Klasse, von der andere Klassen (↑Subklassen) ↑Attribute und ↑Methoden erben. Die ↑Vererbung geht dabei i.d.R. über die nach außen hin sichtbare ↑Schnittstelle der Superklasse hinaus. Superklassen implementieren bzw. definieren normalerweise nur das Notwendigste, sozusagen den „kleinsten gemeinsamen Nenner“. Alle spezifische Funktionalität wird in der ↑Subklasse implementiert.

**System zur Datenverarbeitung** hier: Gesamtsystem für wissenschaftliche Datenverarbeitung von der Datenaufnahme bis zur fertigen Publikation, das alle Aspekte umfasst und das ↑reproduzierbare Wissenschaft möglich macht und gewährleistet. Definitiv ein ↑größeres Projekt, das nicht nur eine ↑monolithische Anwendung umfasst, sondern viele Aspekte darüber hinaus. Setzt entsprechende ↑Infrastruktur und in der Umsetzung der einzelnen Komponenten sauberen Code (↑Clean Code) und eine solide ↑Softwarearchitektur voraus.

**Typisierung** *typing*, Zuweisung eines Typs zu einem Objekt (im abstrakten Sinne) einer Programmiersprache, z.B. Ganzzahl (*integer*) oder Zeichenkette (*string*) im Fall einer Variable. ↑Abstraktion, die die Ausdrucksstärke von Programmiersprachen und Programmen deutlich erhöht, und die Überprüfung der Korrektheit erleichtert sowie Optimierungen ermöglicht. Typisierung kann explizit und implizit erfolgen. Darüber hinaus wird zwischen starker und schwacher Typisierung sowie zwischen statischer und dynamischer Typisierung unterschieden. Jede Art der Typisierung hat ihre Vor- und Nachteile, und unterschiedli-

che Programmiersprachen verwenden unterschiedliche Arten der Typisierung.

**UTC** koordinierte Weltzeit. Die Abkürzung ist ein Kompromiss aus *Coordinated Universal Time* und *Temps Universel Coordonné*, wird inoffiziell aber auch zu *Universal Time Coordinated* ausformuliert.

**Vererbung** *inheritance*, Weitergabe aller Eigenschaften (↑Attribute, ↑Methoden) von einer ↑Superklasse an eine ↑Subklasse. Die Subklasse ist vom gleichen Typ (↑Typisierung) wie die Superklasse, was wiederum die Grundlage der ↑Polymorphie ist. Änderungen der Superklasse wirken sich allerdings auf die Subklasse aus, die ↑Kapselung wird entsprechend geschwächt.

**Version** siehe ↑Revision

**Versionsdatenbank** siehe ↑Repository

**Versionsnummer** hier: eindeutige Bezeichnung einer Version einer Software, deren Kenntnis es erlaubt, auf genau diese Version der Software Bezug zu nehmen.

**Versionsverwaltung** *version control system, VCS*; Software zur Verwaltung unterschiedlicher Versionen von Dateien und Programmen, die den Zugriff auf beliebige ältere als Versionen (↑Revision) gespeicherte Zustände ermöglicht. Gleichzeitig ein wichtiges Werkzeug für die Softwareentwicklung und wesentlicher Aspekt einer Projektinfrastruktur.

**Windows-INI** blockweise strukturiertes ↑Datenformat, das ursprünglich für die Ablage von Konfigurationsoptionen für das Windows-Betriebssystem und darauf laufende Programme entwickelt wurde. Die blockweise Struktur erlaubt zwei Hierarchieebenen: Blöcke und Schlüssel-Wert-Paare. Für weitere Hierarchieebenen und die Ablage beliebig verschachtelter Datenstrukturen müssen hierarchische Datenformate wie ↑XML, ↑JSON oder ↑YAML herangezogen werden.

**XML** *eXtensible Markup Language*, „erweiterbare Auszeichnungssprache“, ↑Auszeichnungssprache zur Darstellung hierarchisch strukturierter

Daten im Format einer Textdatei, die sowohl von Menschen als auch von Maschinen lesbar ist. Der große Vorteil von XML ist seine ↑syntaktische Validierbarkeit, der Nachteil das Verhältnis von beschreibender Syntax zu eigentlichem Inhalt, das sowohl die Dateigröße erheblich erhöhen kann als auch die Lesbarkeit durch Menschen einschränkt. Alternativen, die von Menschen einfacher les- und insbesondere schreibbar sind, sind ↑JSON und ↑YAML.

**YAML** *YAML Ain't Markup Language* (rekursives Akronym, ursprünglich *Yet Another Markup Language*), vereinfachte ↑Auszeichnungssprache (*markup language*)

## Literatur

[1] Edsger W. Dijkstra. The humble programmer. *Communications of the ACM* 15 (1972), S. 859–865.

zur Datenserialisierung (↑Serialisierung). Die grundsätzliche Annahme von YAML ist, dass sich jede beliebige Datenstruktur nur mit assoziativen Listen, Listen (Arrays) und Einzelwerten (Skalaren) darstellen lässt. Durch dieses einfache Konzept ist YAML wesentlich leichter von Menschen zu lesen und zu schreiben als beispielsweise ↑XML, außerdem vereinfacht es die Weiterverarbeitung der Daten, da die meisten Sprachen solche Konstrukte bereits integriert haben. Durch weitgehenden Verzicht auf Klammern ist YAML für Menschen les- und insbesondere schreibbarer als ↑JSON und eignet sich daher gut für die Ablage von Metadaten und Konfigurationen.

[2] Thomas S. Kuhn. *Die Struktur wissenschaftlicher Revolutionen*. Frankfurt am Main: Suhrkamp, 1976.

[3] Robert C. Martin. *Clean Architecture. A Craftman's Guide to Software Structure and Design*. Boston: Prentice Hall, 2018.