

# Digital Skills für Ingenieur\*innen

## 2. Vorlesungstag

### *„Datenformate“*

## Daten – das Gold des 21. Jahrhunderts

Mit dem Aufkommen von Social Media Plattformen, wie z.B.

- LinkedIn (2002)
- Myspace (2003)
- Facebook (2004) und
- Twitter (2007)

haben Internet-User\*innen viele Ihrer eigenen Wünsche/Bedürfnisse preisgegeben. Diese Informationen sind Firmen bares Geld wert, da sie damit individualisierte Werbung schalten können.

## Daten – das Gold des 21. Jahrhunderts

### *Data-driven Marketing*

Mit dem Aufkommen von Social Media Plattformen, wie z.B.

- LinkedIn (2002)
- Myspace (2003)
- Facebook (2004) und
- Twitter (2007)

haben Internet-User\*innen viele Ihrer eigenen Wünsche/Bedürfnisse preisgegeben. Diese Informationen sind Firmen bares Geld wert, da sie damit individualisierte Werbung schalten können.

# Datenformate

## Daten – das Gold des 21. Jahrhunderts

Mit dem Aufkommen von Social Media Plattformen, wie z.B.

- LinkedIn (2002)
- Myspace (2003)
- Facebook (2004) und
- Twitter (2007)

haben Internet-User\*innen viele Ihrer eigenen Wünsche/Bedürfnisse preisgegeben. Diese Informationen sind Firmen bares Geld wert, da sie damit individualisierte Werbung schalten können.

### *Data-driven Marketing*

- *Personalisierung des Kundenerlebnis, steigern der Kundentreue.*

# Datenformate

## Daten – das Gold des 21. Jahrhunderts

Mit dem Aufkommen von Social Media Plattformen, wie z.B.

- LinkedIn (2002)
- Myspace (2003)
- Facebook (2004) und
- Twitter (2007)

haben Internet-User\*innen viele Ihrer eigenen Wünsche/Bedürfnisse preisgegeben. Diese Informationen sind Firmen bares Geld wert, da sie damit individualisierte Werbung schalten können.

### *Data-driven Marketing*

- *Personalisierung des Kundenerlebnis, steigern der Kundentreue.*
- *Steigerung des Erfolgs von Werbekampagnen*

# Datenformate

## Daten – das Gold des 21. Jahrhunderts

Mit dem Aufkommen von Social Media Plattformen, wie z.B.

- LinkedIn (2002)
- Myspace (2003)
- Facebook (2004) und
- Twitter (2007)

haben Internet-User\*innen viele Ihrer eigenen Wünsche/Bedürfnisse preisgegeben. Diese Informationen sind Firmen bares Geld wert, da sie damit individualisierte Werbung schalten können.

### *Data-driven Marketing*

- *Personalisierung des Kundenerlebnis, steigern der Kundentreue.*
- *Steigerung des Erfolgs von Werbekampagnen*
- *Marketingleistung kann präzise bewertet werden. Identifikation von Risiko- und Wachstumsbereichen*

# Datenformate

## Daten – das Gold des 21. Jahrhunderts

Künftig wird allerdings KI unseren Alltag revolutionieren. Ein Beispiel hierfür ist **IBM Watson for Oncology**:

Künstliche Intelligenz – Plattform die weltweit ca. 230 Krankenhäuser bei onkologischen Fragestellungen Therapieoptionen vorschlägt.


→ Die Basis für das Training solcher Systeme sind **Big Data**. Diese Datenbasis muss in einer analysierbaren Form vorliegen.



# Datenformate

## Daten Austausch

Szenario: Austausch von Daten einer **SQL Datenbank** in ein **Tabellenkalkulationsprogramm**.

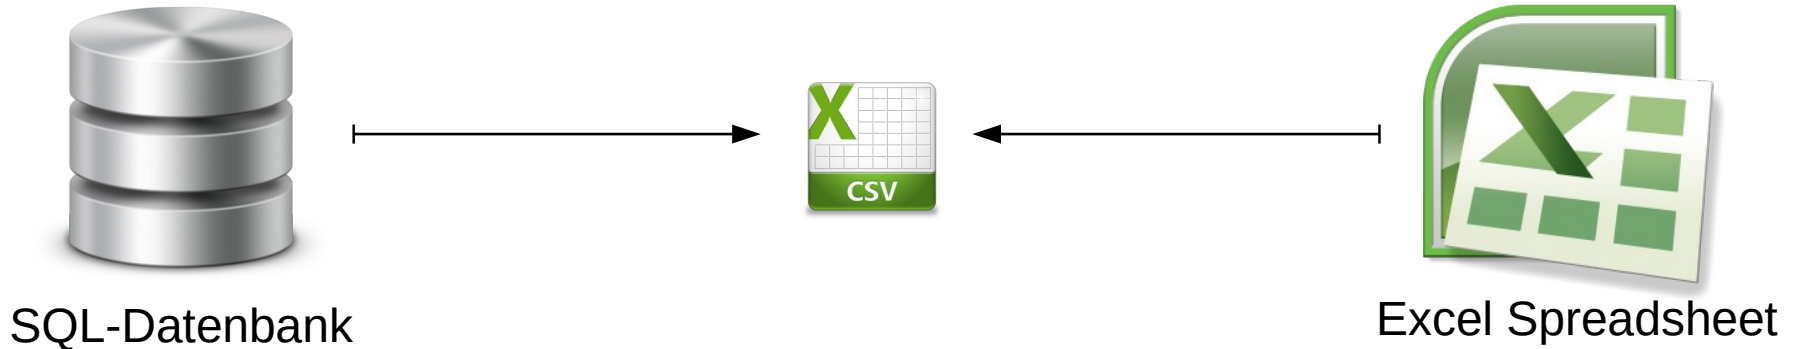




# Datenformate

## Daten Austausch

Szenario: Austausch von Daten einer **SQL Datenbank** in ein **Tabellenkalkulationsprogramm**.



## Strukturierte Daten (z.B. CSV)

*„The comma separated values format (CSV) has been used for exchanging and converting data between various spreadsheet programs for quite some time. Surprisingly, while this format is very common, it has never been formally documented.“*

[2]

Bei einer CSV – Datei handelt es sich um **strukturierte Daten**. Denn es handelt sich dabei um Daten, die in einem vorgegebenen Format strukturiert werden, bevor sie im Datenspeicher abgelegt werden.

Innerhalb der **RFC 4180** werden die nachfolgenden **sieben Regeln** für die Struktur formalisiert.

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>

## Aufbau einer CSV – Datei

1. „Jeder Datensatz befindet sich in einer separaten Zeile, die durch einen Zeilenumbruch (CRLF = Carriage Return Line Feed) getrennt ist.“ <sup>[1]</sup> Zum Beispiel:

aaa,bbb,ccc [CRLF]

zzz,yyy,xxx [CRLF]

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>

## Aufbau einer CSV – Datei

2. „Der letzte Datensatz in der Datei kann einen Zeilenumbruch am Ende haben oder auch nicht.“ <sup>[1]</sup> Zum Beispiel:

```
aaa,bbb,ccc [CRLF]
zzz,yyy,xxx
```

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>

## Aufbau einer CSV – Datei

3. „Möglicherweise erscheint als erste Zeile der Datei eine optionale Kopfzeile mit dem gleichen Format wie normale Datensatzzeilen. Dieser Header enthält Namen, die den Feldern in der Datei entsprechen, und sollte die gleiche Anzahl von Feldern enthalten wie die Datensätze im Rest der Datei (das Vorhandensein oder Fehlen der Header-Zeile sollte über den optionalen Parameter "header" dieser Datei angegeben werden *Mime Typ*).“ <sup>[1]</sup> Zum Beispiel:

```
feldname,feldname,feldname [CRLF]
aaa,bbb,ccc [CRLF]
zzz,yyy,xxx
```

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>

## Aufbau einer CSV – Datei

4. „Innerhalb des Headers und jedes Datensatzes können ein oder mehrere Felder vorhanden sein, die durch Kommas getrennt sind. Jede Zeile sollte in der gesamten Datei die gleiche Anzahl von Feldern enthalten. Leerzeichen werden als Teil eines Feldes betrachtet und sollten nicht ignoriert werden. Dem letzten Feld im Datensatz darf kein Komma folgen.“ <sup>[1]</sup> Zum Beispiel:

aaa,bbb,ccc

Anmerkung: Als Trennzeichen werden in der Praxis auch Semikolon, Tabulator, Leerzeichen, usw. genutzt.

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>

## Aufbau einer CSV – Datei

5. „Jedes Feld kann in doppelte Anführungszeichen gesetzt werden oder nicht (einige Programme, wie z. B. Microsoft Excel, verwenden jedoch überhaupt keine doppelten Anführungszeichen). Wenn Felder nicht in doppelte Anführungszeichen eingeschlossen sind, dürfen innerhalb der Felder keine doppelten Anführungszeichen erscheinen.“ <sup>[1]</sup>

Zum Beispiel:

```
"aaa","bbb","ccc" [CRLF]  
zzz,yyy,xxx
```

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>

## Aufbau einer CSV – Datei

6. „Felder mit Zeilenumbrüchen (CRLF), doppelten Anführungszeichen und Kommas sollten in doppelte Anführungszeichen gesetzt werden.“ <sup>[1]</sup> Zum Beispiel:

```
"aaa","b [CRLF]
bb","ccc" [CRLF]
zzz,yyy,xxx
```

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>



## Aufbau einer CSV – Datei

7. „Wenn doppelte Anführungszeichen verwendet werden, um Felder zu umschließen, muss ein doppeltes Anführungszeichen, das innerhalb eines Felds erscheint, durch ein vorangestelltes doppeltes Anführungszeichen entwertet werden.“ <sup>[1]</sup> Zum Beispiel:

"aaa","b""bb","ccc"

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>

# Datenformate

Vorname	Nachname	Geburtsdatum	Postleitzahl
Sieglinde	Müller	24.03.1928	66113
Josef	Franz	04.05.1948	66113
Peter	Jungblut	06.07.1963	66538

Tabelle 1: Personentabelle



# Datenformate

Vorname	Nachname	Geburtsdatum	Postleitzahl
Sieglinde	Müller	24.03.1928	66113
Josef	Franz	04.05.1948	66113
Peter	Jungblut	06.07.1963	66538

Tabelle 1: Personentabelle



```
Vorname;Nachname;Geburtsdatum;Postleitzahl  
"Sieglinde";"Müller";"24.03.1928";"66113"  
"Josef";"Franz";"04.05.1948";"66113"  
"Peter";"Jungblut";"06.07.1963";"66538"
```

Personen.csv

## Vorteile strukturierter Daten

### Vorteile

- **Einfach nutzbar** für Machine Learning Algorithmen. Da die Daten strukturiert sind, können Sie leicht bearbeitet und abgefragt werden.
- Ein\*e durchschnittliche\*r Benutzer\*in, die/der sich mit dem Thema auskennt, auf das sich die Daten beziehen, kann diese auch nutzen (und auch lesen).
- Da strukturierte Daten **weit verbreitet** sind, unterstützen viele Tools Import-/Export-Möglichkeiten.

## Nachteile strukturierter Daten

### Nachteile

- Ein vordefinierter Zweck schränkt die Verwendungsmöglichkeiten ein. Somit haben strukturierte Daten eine **geringere Flexibilität** und **Anwendungsmöglichkeit**.
- Das Speichern strukturierter Daten folgt starren Schemata. Jede Anforderungsänderung bedeutet: alle strukturierten Daten müssen aktualisiert werden, damit sie den neuen Anforderungen entsprechen. Dadurch entsteht ein **größerer Aufwand von Zeit** und **Ressourcen**.

## Semistrukturierte Daten (z.B. JSON)

### JSON

*„JavaScript Object Notation (JSON) ist ein einfaches, textbasiertes, sprachunabhängiges Datenaustauschformat. Es wurde vom ECMAScript Programming Language Standard abgeleitet. JSON definiert einen kleinen Satz von Formatierungsregeln für die portable Darstellung strukturierter Daten.“* [2] [3]

JSON wird durch die beiden inhaltsgleichen Standards **RFC 8259** und **ECMA-404** definiert.

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

[3]: Vgl. <https://www.ecma-international.org/publications-and-standards/standards/ecma-404/>

## JSON

### JSON Grammatik (1)

„Ein JSON-Text ist eine *Folge von Tokens*. Der Token-Satz umfasst *sechs Strukturzeichen, Zeichenfolgen, Zahlen und drei wörtliche Namen*.“ [2]

### Strukturzeichen

1. begin-array	= [	2. end-array	= ]
3. begin-object	= {	4. end-object	= }
5. name-seperator	= :	6. value-seperator	= ,

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

## JSON

### JSON Grammatik (2)

*„Unbedeutende Leerzeichen sind vor oder nach jedem der sechs Strukturzeichen erlaubt.“ [2]*

**Unbedeutende Leerzeichen** sind definiert als Space (%x20), Horizontal Tab (%x09), Line feed oder New line (%x0A) und Carriage Return (%x0D).

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>



# Datenformate

## JSON

### Werte

„Ein JSON-Wert *muss* ein *Objekt*, ein *Array*, eine *Zahl* oder eine *Zeichenfolge* oder einer der *folgenden drei wörtliche Namen* sein: false, null, true. Die wörtlichen Namen *müssen* in Kleinbuchstaben geschrieben werden. Andere wörtliche Namen sind nicht zulässig.“ [2]

value = false / null / true / object / array / number / string

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

## JSON

### Objekte (1)

„Eine Objektstruktur wird als *Paar geschweifter Klammern* dargestellt, die *null oder mehr* *Attribut-Wert-Paare* (oder Mitglieder) umgeben. Ein *Attribut* ist eine *Zeichenfolge*. *Nach jedem Attribut* steht ein *einzelner Doppelpunkt*, der das *Attribut vom Wert trennt*. Ein *einzelnes Komma* trennt einen *Wert* von einem *nachfolgenden Attribut*. Die Attribute innerhalb eines Objekts *sollten* eindeutig sein.“ [2]

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

## JSON

### Objekte (2)

„Ein Objekt, dessen Attribute *alle eindeutig* sind, ist in dem Sinne *interoperabel*, dass alle Softwareimplementierungen, die dieses Objekt empfangen, sich auf die Attribut-Wert-Zuordnungen einigen werden. Wenn die Attribute innerhalb eines Objekts *nicht eindeutig sind*, ist das Verhalten von Software, die ein solches Objekt empfängt, *unvorhersehbar*. Viele Implementierungen melden nur das letzte Attribut-Wert-Paar.“ [2]

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

## JSON

### Arrays

„Eine Array-Struktur wird als *eckige Klammern* dargestellt, die *null oder mehr Werte (oder Elemente)* umgeben. Elemente werden durch *Kommas* getrennt. Es ist nicht erforderlich, dass die Werte in einem Array denselben Typ haben.“ [2]

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

## JSON

### Zahlen (1)

„Die Darstellung von Zahlen ähnelt der in den meisten Programmiersprachen verwendeten. Eine Zahl wird zur **Basis 10** mit **Dezimalziffern** dargestellt. Es enthält eine **ganzzahlige Komponente**, der **optional** ein **Minuszeichen** vorangestellt werden kann, **gefolgt** von einem **Bruchteil und/oder** einem **Exponententeil**. **Führende Nullen** sind nicht erlaubt.“ [2]

number = [ minus ] int [ frac ] [ exp ]

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

## JSON

### Zahlen (2)

„Ein *Bruchteil* ist ein *Dezimalpunkt*, gefolgt von einer oder mehreren Ziffern. Ein *Exponent* beginnt mit dem *Buchstaben E* in Groß- oder Kleinbuchstaben, dem ein Plus- oder Minuszeichen folgen kann. Auf das *E* und das optionale Zeichen folgen eine oder mehrere Ziffern.“ [2]

decimal-point = .      digit1-9 = 1-9      e = e E

exp                = e [minus/plus]1\*DIGIT

frac                = decimal-point 1\*DIGIT

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

## JSON

### Strings

„Die Darstellung von Strings ähnelt den Konventionen, die in der C-Familie von Programmiersprachen verwendet werden. Ein String **beginnt** und **endet mit Anführungszeichen**. Alle Unicode-Zeichen können innerhalb der Anführungszeichen gesetzt werden, mit Ausnahme der Zeichen, die entwertet werden müssen: **Anführungszeichen**, **Backslash** und die **Steuerzeichen** (U+0000 bis U+001F).“ [2]

Anmerkung: Entwertet wird kompakt mit `"\"` oder mit `"\u+Unicode Code Point"`, z.B. kann der String `"\"` als `"\u005C"` oder kurz als `"\"` repräsentiert werden.

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

## JSON

### Beispiel

```
{  
  "Person":{  
    "name":"John Smith",  
    "isAlive":true,  
    "age":25,  
    "address":{  
      "cityStreet":"New York, 21 2nd Street",  
      "postalCode":"10021-31\00"  
    },  
    "children":[  
      "peter",  
      12,  
      false  
    ],  
    "spouse":null  
  }  
}
```

[3]

[3]: Vgl. <https://jsonformatter.curiousconcept.com/>



## Semistrukturierte Daten (z.B. XML)

### XML

„**Extensible Markup Language**, abgekürzt XML, beschreibt eine Klasse von Datenobjekten, die als XML-Dokumente bezeichnet werden, und beschreibt teilweise das Verhalten von Computerprogrammen, die sie verarbeiten. XML ist ein Anwendungsprofil oder eine eingeschränkte Form von SGML, der **Standard Generalized Markup Language**. XML-Dokumente sind konstruktionsbedingt konforme SGML-Dokumente.“

[4]: Vgl. <https://www.w3.org/TR/REC-xml/>

## XML

„XML ist eine *Auszeichnungssprache* zum *Strukturieren* von *Dokumenten* und *Daten*. *Auszeichnungssprachen* (engl. Markup Languages) geben Regeln vor, mit denen Teile eines Textes in bestimmter Weise *markiert* (ausgezeichnet) *werden* können, um ihnen *zusätzliche Semantik* und *Eigenschaften hinzuzufügen*, meist mit dem Ziel einen Text maschinenlesbar zu machen.“

[4]: Vgl. <https://www.w3.org/TR/REC-xml/>

## XML

### Beispiel

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<verzeichnis>
  <titel>Wikipedia Städteverzeichnis</titel>
  <eintrag>
    <stichwort>Genf</stichwort>
    <eintragstext>Genf ist der Sitz von ...</eintragstext>
  </eintrag>
  <eintrag>
    <stichwort>Köln</stichwort>
    <eintragstext>Köln ist eine Stadt, die ...</eintragstext>
  </eintrag>
</verzeichnis>
```

[5]

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

# Datenformate

## XML

## Beispiel

**Dokumententität** : Dies  
ist die Haupt-XML-Datei.



```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<verzeichnis>
  <titel>Wikipedia Städteverzeichnis</titel>
  <eintrag>
    <stichwort>Genf</stichwort>
    <eintragstext>Genf ist der Sitz von ...</eintragstext>
  </eintrag>
  <eintrag>
    <stichwort>Köln</stichwort>
    <eintragstext>Köln ist eine Stadt, die ...</eintragstext>
  </eintrag>
</verzeichnis>
```

[5]

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

# Datenformate

## XML

XML-Deklaration enthält:

- Version
- Zeichenkodierung
- Verarbeitbarkeit ohne Document Type Definition

## Beispiel

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<verzeichnis>
  <titel>Wikipedia Städteverzeichnis</titel>
  <eintrag>
    <stichwort>Genf</stichwort>
    <eintragstext>Genf ist der Sitz von ...</eintragstext>
  </eintrag>
  <eintrag>
    <stichwort>Köln</stichwort>
    <eintragstext>Köln ist eine Stadt, die ...</eintragstext>
  </eintrag>
</verzeichnis>
```

[5]

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

# Datenformate

## XML

Das Dokument besitzt **genau ein Wurzelement**. Als Wurzelement wird dabei das jeweils **äußerste Element** bezeichnet, z.B. ist in diesem Fall das Element **verzeichnis** Wurzelement (Root-Element).

## Beispiel

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>  
<verzeichnis>  
  <titel>Wikipedia Städteverzeichnis</titel>  
  <eintrag>  
    <stichwort>Genf</stichwort>  
    <eintragstext>Genf ist der Sitz von ...</eintragstext>  
  </eintrag>  
  <eintrag>  
    <stichwort>Köln</stichwort>  
    <eintragstext>Köln ist eine Stadt, die ...</eintragstext>  
  </eintrag>  
</verzeichnis>
```

[5]

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

# Datenformate

## XML

**Starttag** für den Beginn des  
Wurzelement verzeichnis.

## Beispiel

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>  
<verzeichnis>  
  <titel>Wikipedia Städteverzeichnis</titel>  
  <eintrag>  
    <stichwort>Genf</stichwort>  
    <eintragstext>Genf ist der Sitz von ...</eintragstext>  
  </eintrag>  
  <eintrag>  
    <stichwort>Köln</stichwort>  
    <eintragstext>Köln ist eine Stadt, die ...</eintragstext>  
  </eintrag>  
</verzeichnis>
```

[5]

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

# Datenformate

## XML

**Endtag** für das Ende des Wurzelement  
verzeichnis.

## Beispiel

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<verzeichnis>
  <titel>Wikipedia Städteverzeichnis</titel>
  <eintrag>
    <stichwort>Genf</stichwort>
    <eintragstext>Genf ist der Sitz von ...</eintragstext>
  </eintrag>
  <eintrag>
    <stichwort>Köln</stichwort>
    <eintragstext>Köln ist eine Stadt, die ...</eintragstext>
  </eintrag>
</verzeichnis>
```

[5]

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)



# Datenformate

## XML

Elemente ohne Inhalt können mit einem **Leertag** gekennzeichnet werden, z.B. `<leertag/>`.

## Beispiel

```
<?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<verzeichnis>
  <titel>Wikipedia Städteverzeichnis</titel>
  <eintrag>
    <stichwort>Genf</stichwort>
    <eintragstext>Genf ist der Sitz von ...</eintragstext>
  </eintrag>
  <eintrag>
    <stichwort>Köln</stichwort>
    <eintragstext>Köln ist eine Stadt, die ...</eintragstext>
  </eintrag>
</verzeichnis>
```

[5]

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

## XML

### Wohlgeformtheit (well-formed)

„Ein XML-Dokument heißt „wohlgeformt“ (oder englisch well-formed), wenn es alle XML-Regeln einhält.“ [5]

- Das Dokument besitzt **genau ein Wurzelement**. Als Wurzelement wird dabei das jeweils äußerste Element bezeichnet.
- Alle Elemente mit Inhalt besitzen einen Start- und einen Endtag (z. B. <eintrag>Eintrag 1</eintrag>). Elemente ohne Inhalt können mit einem Leertag gekennzeichnet werden (z. B. <eintrag />)

[5]: [Vgl: https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

## XML

### Wohlgeformtheit (well-formed)

- Die Start- und Endtags sind **ebenentreu-paarig** verschachtelt. Das bedeutet, dass alle Elemente geschlossen werden müssen, **bevor** die **End-Auszeichner** des **entsprechenden Elternelements** oder die **Beginn-Auszeichner** eines **Geschwisterelements** erscheinen.
- Ein Element darf **nicht mehrere Attribute mit demselben Namen** besitzen.

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

## XML

### Wohlgeformtheit (well-formed)

- Attributwerte müssen in **Anführungszeichen** stehen ("..." oder '...').
- Die Start- und Endtags beachten die Groß- und Kleinschreibung (z. B. `<eintrag></Eintrag>` ist nicht gültig).

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)

# Datenformate

## Fazit

CSV		JSON		XML	
- geringe Flexibilität	+ einfach zu implementieren und zu parsen	- ist keine so robuste Datenstruktur wie XML	+ ist in seiner erweiterten Form einfacher zu lesen als XML	- sehr ausführlich und redundant.	+ XML ermöglicht die Validierung mit DTD und Schema
- nicht geeignet für verschachtelte Strukturen	+ kompakt im Gegensatz zu XML, da keine Tags verwendet werden	- ist nicht gut Informationen aus verschiedenen Systemen zu kombinieren	+ geringere Zeichenanzahl → geringere Overhead bei Datentransfer	- weniger übersichtlich als JSON	+ Plattform und Programmiersprachen unabhängig
- keine Unterscheidung zwischen Zahlen und Text	+ leicht zu generieren	- Fehler sind teilweise schwerer festzustellen als in XML	+ einfacher zu parsen	- unterstützt keine Arrays.	+ Unicode → Transport jeder menschlichen Sprache möglich

## Literatur

[1]: Vgl. <https://datatracker.ietf.org/doc/html/rfc4180>

[2]: Vgl. <https://datatracker.ietf.org/doc/html/rfc8259>

[3]: Vgl.

<https://www.ecma-international.org/publications-and-standards/standards/ecma-404/>

[4]: Vgl. <https://www.w3.org/TR/REC-xml/>

[5]: Vgl. [https://de.wikipedia.org/wiki/Extensible\\_Markup\\_Language](https://de.wikipedia.org/wiki/Extensible_Markup_Language)