Abstract

XML Schema wird als Grundlage für eine zunehmende Anzahl von XML-Technologien (Web Services, XQuery, XSLT 2.0) immer wichtiger. XML Schema führt als wichtigste Neuerung eine Typebene in die Welt von XML ein, die aus zwei grundlegenden Arten von Typen (*Simple* und *Complex Types*) besteht. Dieses Typkonzept und die Konsequenzen für XML-Anwendungen werden in dieser Session vorgestellt.

Erik Wilde – XML Schema 2

Übersicht

- DTDs → XML Schema
- Anwendungen von XML Schema
- Eigenschaften von XML Schema
  - Typen und ihre Verwendung
  - lokale und globale Deklarationen
- Umgang mit XML Schema
  - Modellierung und Programmierung
- Zusammenfassung

Nachteile von DTDs

- keine Beziehungen zwischen Elementtypen
  - keine Typ-Hierarchie der Elemente
  - zusammenhangsloses Nebeneinander
- keine Unterstützung von Wiederverwendung
  - verbreitetes Parameter Entity Design Pattern
- keine anwendungsorientierten Datentypen
- keine Unterstützung für XML Namespaces
  - "DTDs and Namespaces don't mix"
- keine XML Syntax
  - kann nicht mit XML Tools verarbeitet werden

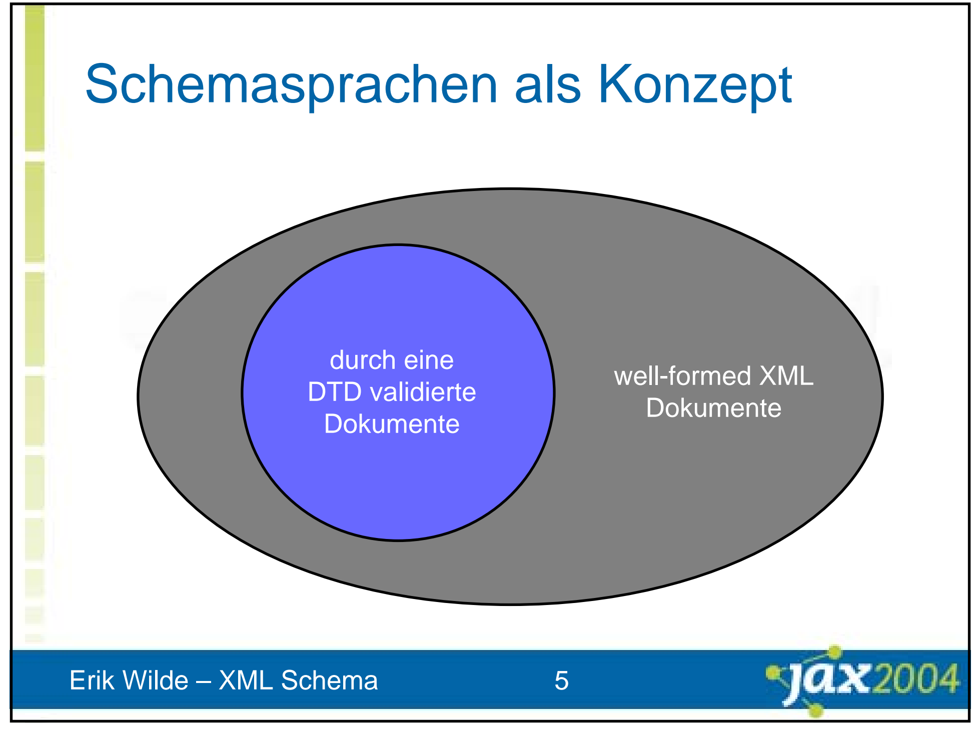
Schemasprachen als Konzept
durch eine DTD validierte Dokumente
well-formed XML Dokumente
Erik Wilde – XML Schema
5
jax2004

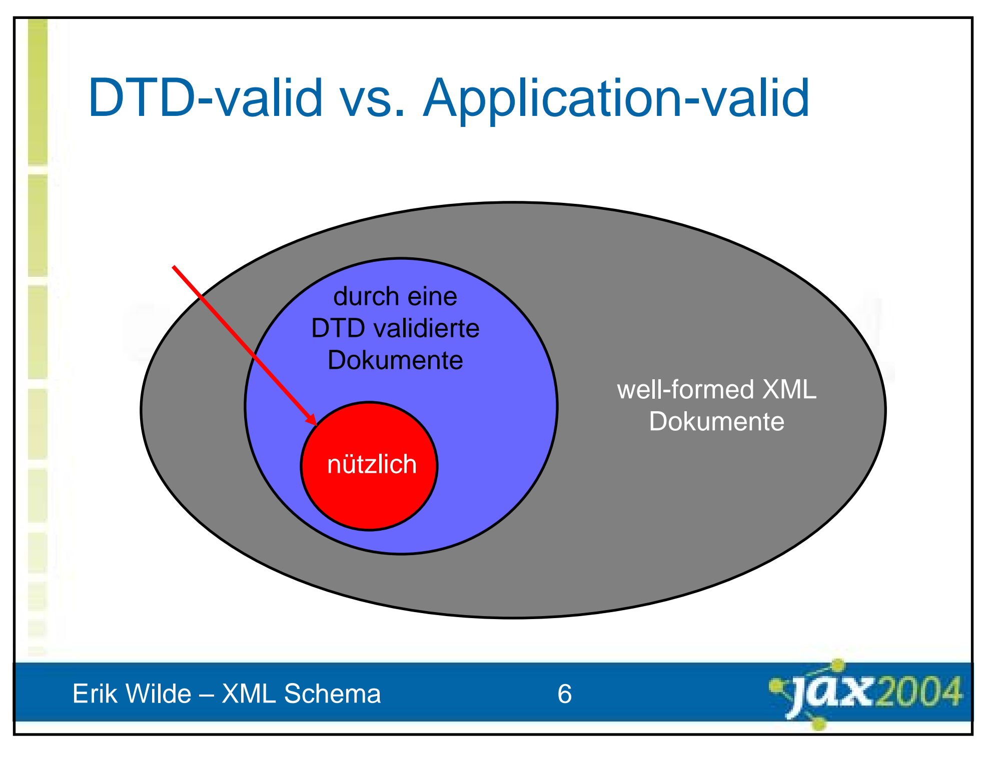
DTD-valid vs. Application-valid
durch eine DTD validierte Dokumente
nützlich
well-formed XML Dokumente
Erik Wilde – XML Schema
6
jax2004

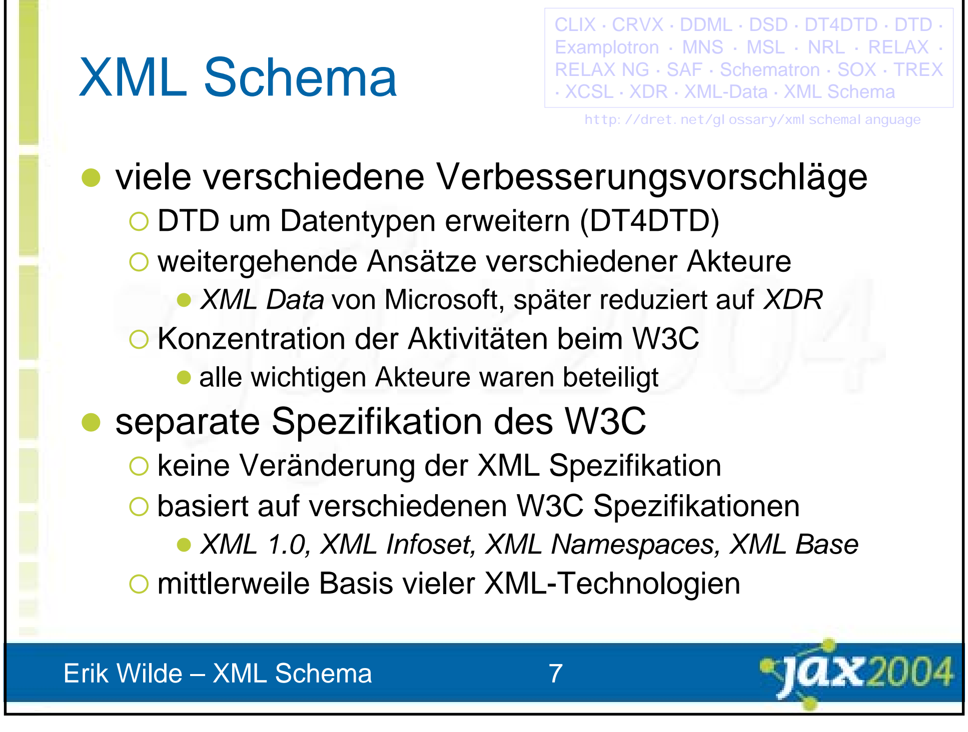
XML Schema
CLIX · CRVX · DDML · DSD · DT4DTD · DTD · Examplotron · MNS · MSL · NRL · RELAX · RELAX NG · SAF · Schematron · SOX · TREX · XCSL · XDR · XML-Data · XML Schema
http://dret.net/glossary/xmlschemalanguage
viele verschiedene Verbesserungsvorschläge
DTD um Datentypen erweitern (DT4DTD)
weitergehende Ansätze verschiedener Akteure
XML Data von Microsoft, später reduziert auf XDR
Konzentration der Aktivitäten beim W3C
alle wichtigen Akteure waren beteiligt
separate Spezifikation des W3C
keine Veränderung der XML Spezifikation
basiert auf verschiedenen W3C Spezifikationen
XML 1.0, XML Infoset, XML Namespaces, XML Base
mittlerweile Basis vieler XML-Technologien
Erik Wilde – XML Schema 7
jax2004

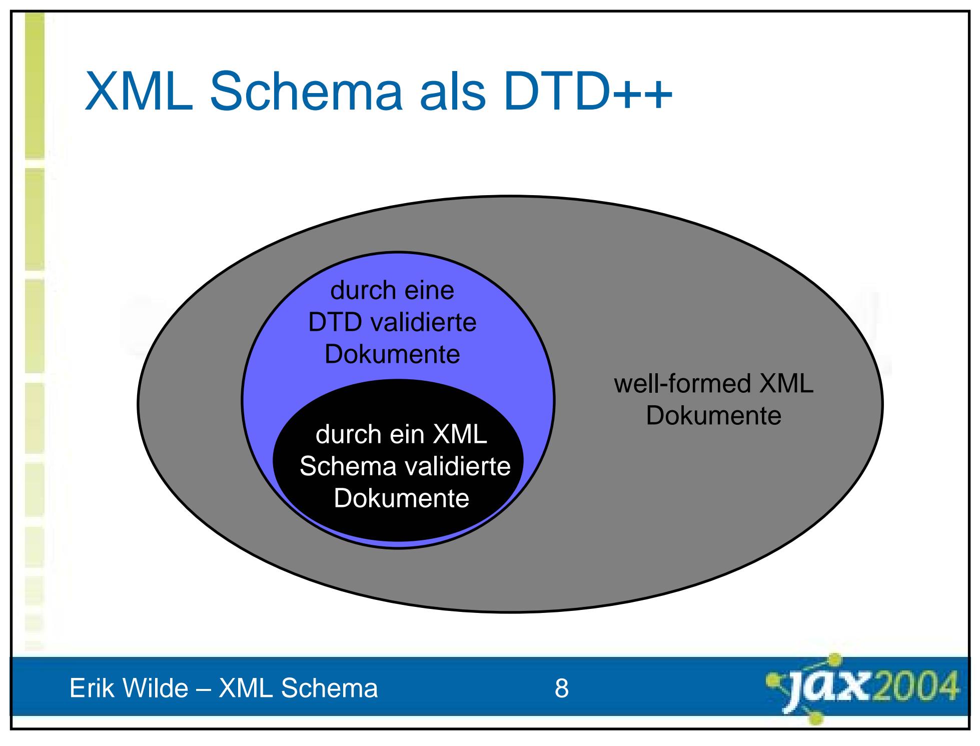
XML Schema als DTD++
durch eine DTD validierte Dokumente
durch ein XML Schema validierte Dokumente
well-formed XML Dokumente
Erik Wilde – XML Schema 8
jax2004

Schema-valid vs. Application-valid

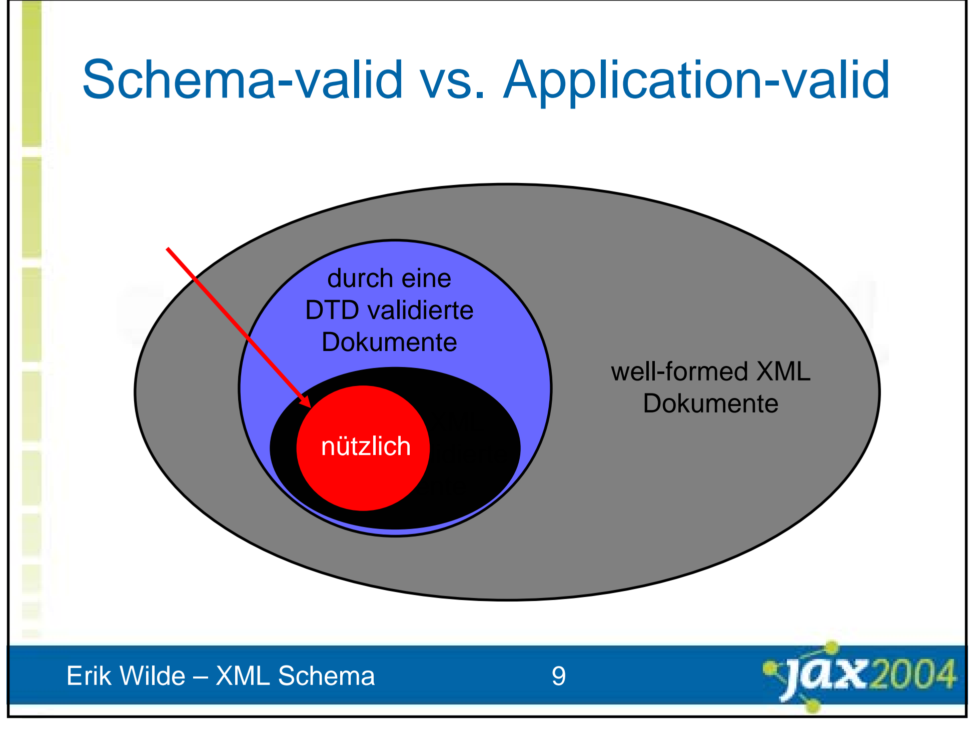

Valid und schema-valid XML

- XML unterscheidet zwischen zwei "Levels"
  - *well-formed* gehorchen dem XML-Standard
  - *valid* sind well-formed und gehorchen einer DTD
- well-formed und valid Konzepte
  - sind direkt im XML Standard definiert
  - können mit DTD und Dokument verifiziert werden
- *schema-valid* Dokumente
  - müssen gemäss einem XML Schema validiert werden
  - gibt es nur mit XML Schema Applikationen
  - haben mehr Randbedingungen als valid Dokumente

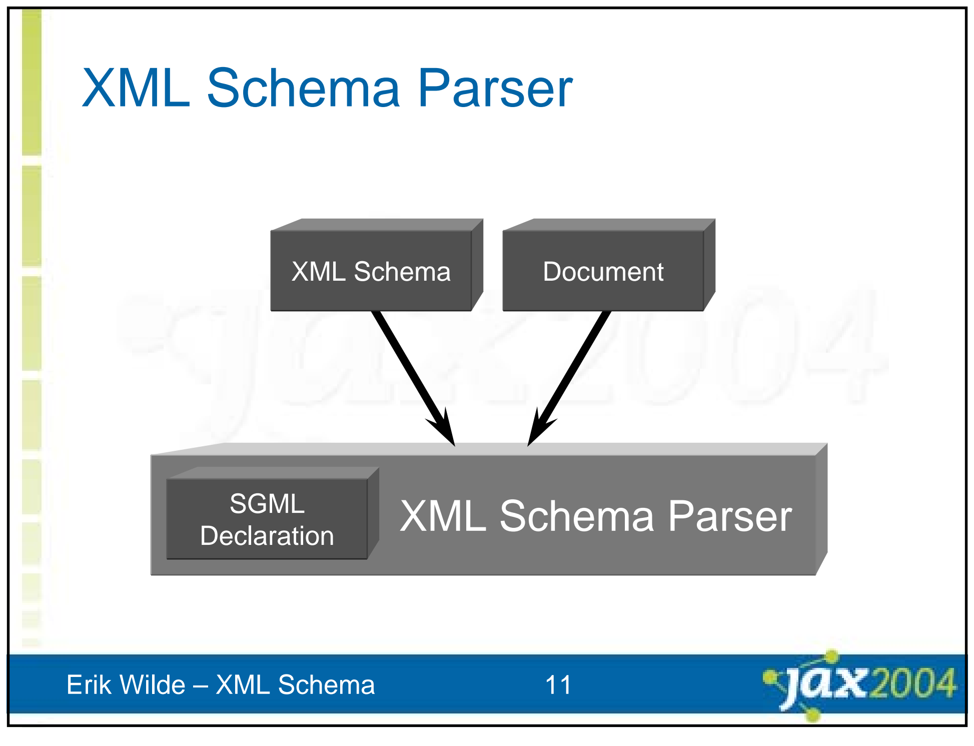
XML Schema Parser
XML Schema
Document
SGML
Declaration
XML Schema Parser
Erik Wilde – XML Schema
11
jax2004

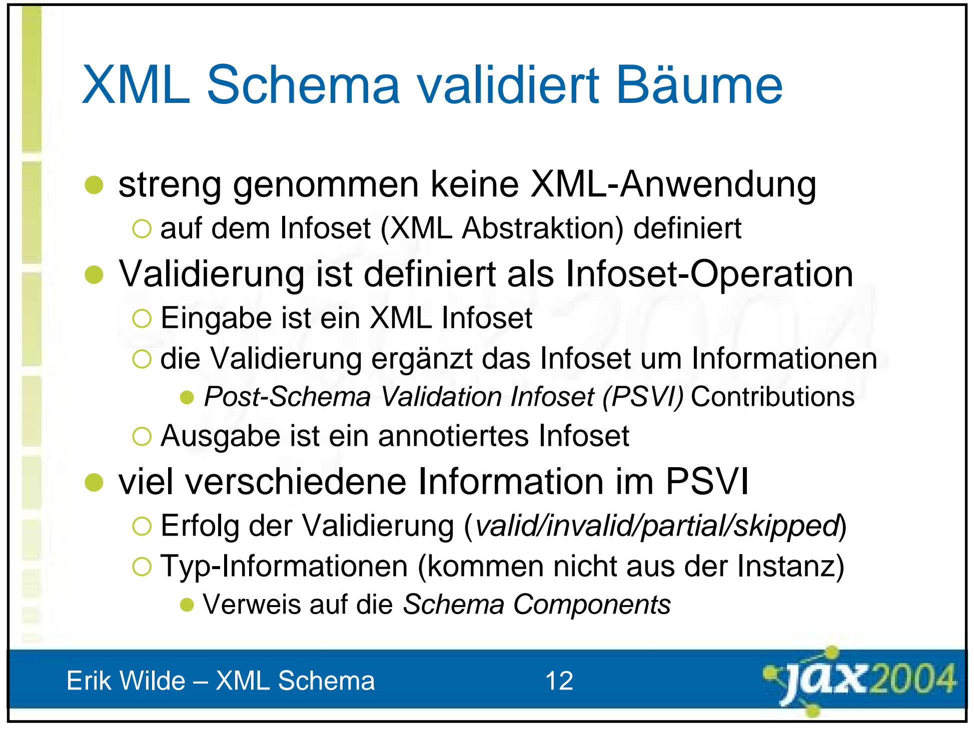
XML Schema validiert Bäume
streng genommen keine XML-Anwendung
auf dem Infoset (XML Abstraktion) definiert
Validierung ist definiert als Infoset-Operation
Eingabe ist ein XML Infoset
die Validierung ergänzt das Infoset um Informationen
Post-Schema Validation Infoset (PSVI) Contributions
Ausgabe ist ein annotiertes Infoset
viel verschiedene Information im PSVI
Erfolg der Validierung (valid/invalid/partial/skipped)
Typ-Informationen (kommen nicht aus der Instanz)
Verweis auf die Schema Components
Erik Wilde – XML Schema
12
jax2004

XML Schema & Web Services

- Web Services sind XML-basierte Applikationen
  - Definition der Schnittstellen mittels *WSDL*
    - Typdefinitionen in WSDL benutzen XML Schema
  - Austausch der Daten mittels *SOAP*
    - Instanzen von XML Schema definierten Schnittstellen
- Modellierung von WSDL Datentypen
  - im einfachsten Fall Generierung aus einer Instanz
    - schnell und einfach, aber kein "gutes" XML Schema
  - für langlebige komplexe Anwendungen: gute Modelle
    - Versionierung der WSDL Schnittstellen
    - u.U. Koexistenz verschiedener Softwareversionen

Erik Wilde – XML Schema 13

XML Schema & XQuery

- XQuery wird die Abfragesprache für XML
  - in der ersten Version keine Manipulation von Daten
  - zum grossen Teil auf XPath 2.0 beruhend
- Abfragesprachen brauchen Datentypen
  - ansonsten gibt es nur textuelle Vergleiche
    - untauglich für Zahlen, Daten, Zeiten, ...
  - ansonsten gibt es keine Relationen
    - grösser, kleiner, Intervalle, ...
- XQuery benutzt die XML Schema Datentypen
  - an sich benutzt XQuery das XPath 2.0 Datenmodell

Erik Wilde – XML Schema 14

XML Schema & XSLT 2.0

- XSLT 2.0 erweitert XSLT 1.0 stark
  - deutliche Verbesserung des Sprachumfangs
  - deutliche Verbesserung der Expression Language
- XSLT 1.0 hat ein sehr einfaches Datenmodell
  - XPath 1.0: Node Sets, Boolean, Number, String
  - keine weitergehenden Datentypen
    - Daten, Zeiten, Zeitintervalle, ...
    - keine Operationen auf solchen Werten möglich
- XSLT 2.0 benutzt die XML Schema Datentypen
  - an sich benutzt XSLT 2.0 das XPath 2.0 Datenmodell

Erik Wilde – XML Schema 15

Was ist neu an XML Schema?

- XML Schema führt Datentypen ein
  - Datentypkonzept orthogonal zu XML
    - soweit es eben geht, XML 1.0 bleibt unverändert
  - *Simple Types* und *Complex Types*
- XML Schema führt Typableitungen ein
  - verschiedene Arten der Typableitung sind möglich
  - es ergibt sich eine Typhierarchie
- XML Schema modernisiert `ID`/`IDREF`
  - (fast) alles wird besser als in DTDs
  - aber der `IDREFS` Typ wird nicht mehr unterstützt

Erik Wilde – XML Schema 16

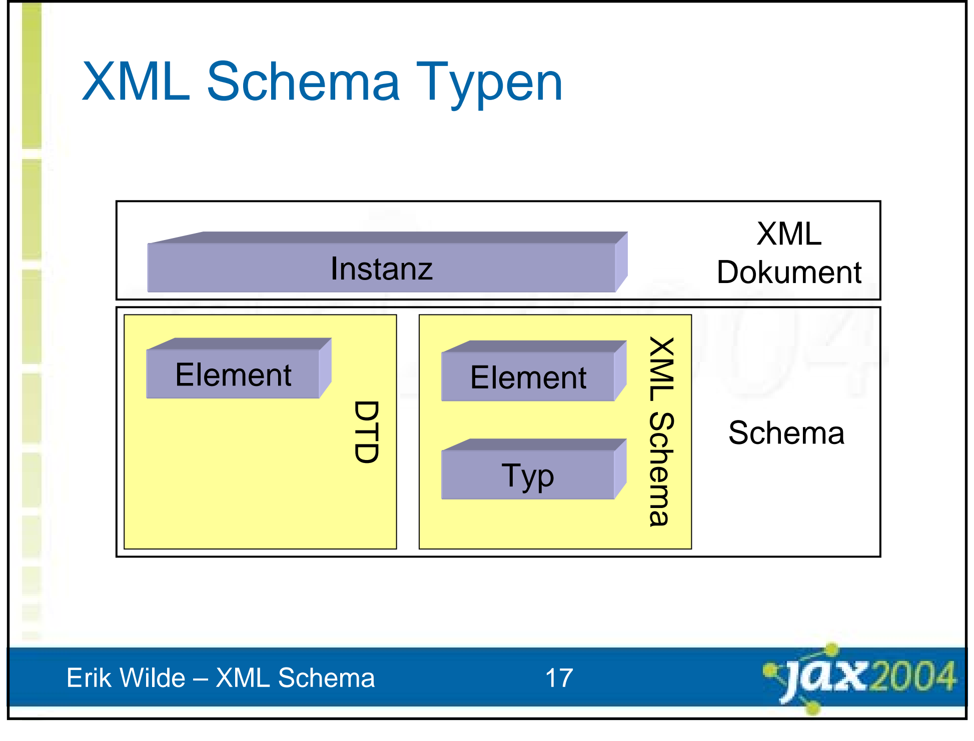
XML Schema Typen
Instanz
XML
Dokument
Element
DTD
Element
Typ
XML Schema
Schema
Erik Wilde – XML Schema
17
jax2004

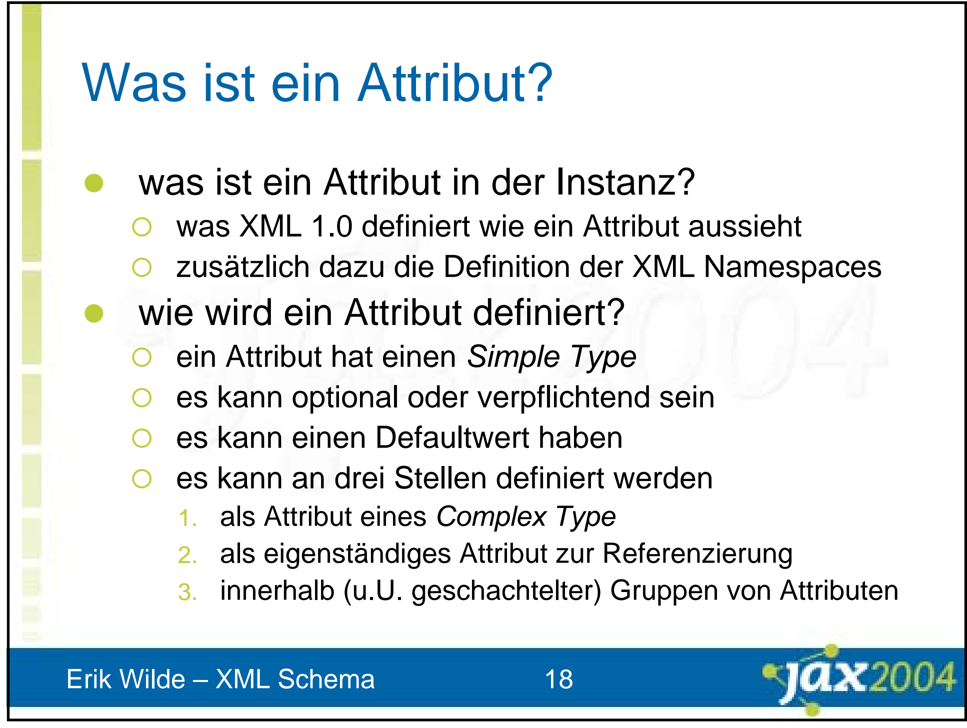
Was ist ein Attribut?
was ist ein Attribut in der Instanz?
was XML 1.0 definiert wie ein Attribut aussieht
zusätzlich dazu die Definition der XML Namespaces
wie wird ein Attribut definiert?
ein Attribut hat einen Simple Type
es kann optional oder verpflichtend sein
es kann einen Defaultwert haben
es kann an drei Stellen definiert werden
1. als Attribut eines Complex Type
2. als eigenständiges Attribut zur Referenzierung
3. innerhalb (u.U. geschachtelter) Gruppen von Attributen
Erik Wilde – XML Schema
18
jax2004

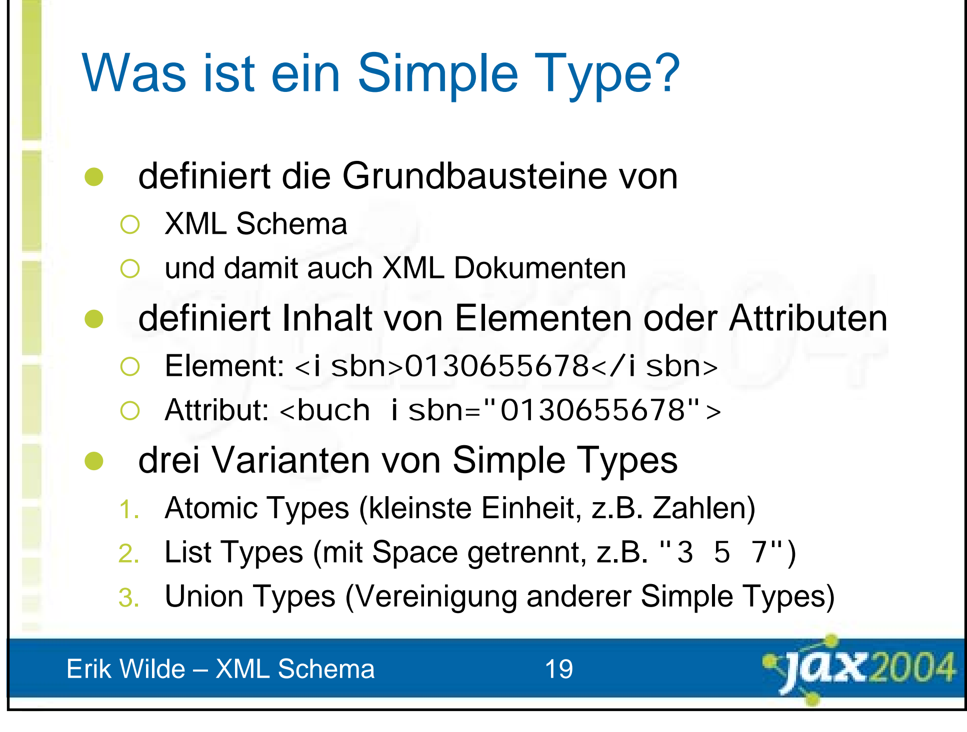
Was ist ein Simple Type?
definiert die Grundbausteine von
XML Schema
und damit auch XML Dokumenten
definiert Inhalt von Elementen oder Attributen
Element: <isbn>0130655678</isbn>
Attribut: <buch isbn="0130655678">
drei Varianten von Simple Types
1. Atomic Types (kleinste Einheit, z.B. Zahlen)
2. List Types (mit Space getrennt, z.B. "3 5 7")
3. Union Types (Vereinigung anderer Simple Types)
Erik Wilde – XML Schema
19
jax2004

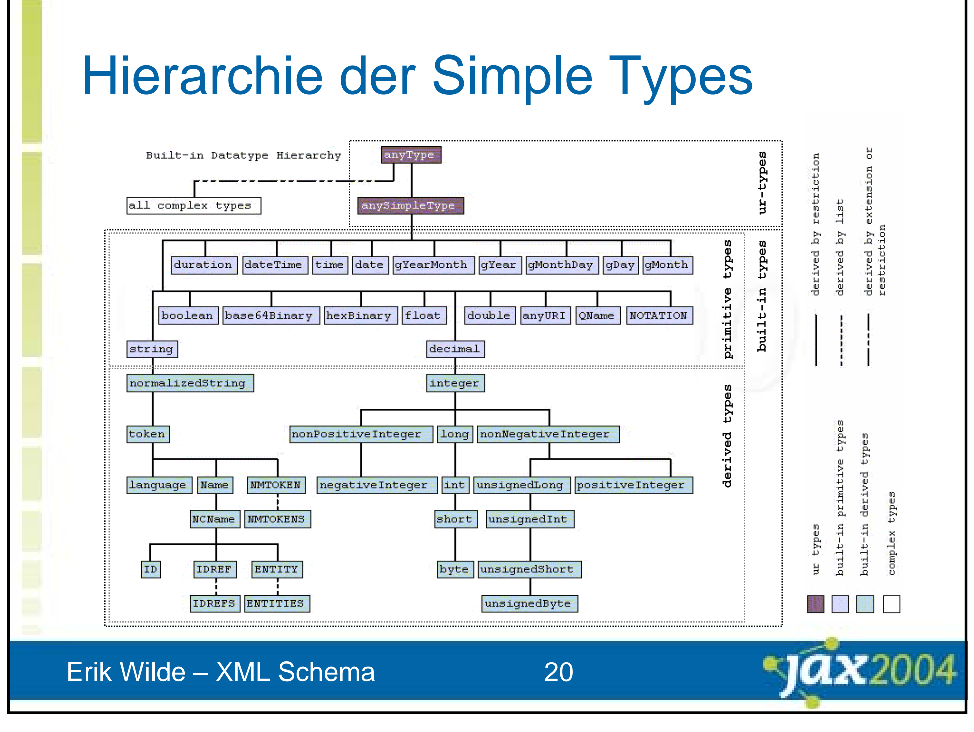
Hierarchie der Simple Types
Built-in Datatype Hierarchy
anyType
all complex types
anySimpleType
ur-types
duration
dateTime
time
date
gYearMonth
gYear
gMonthDay
gDay
gMonth
boolean
base64Binary
hexBinary
float
double
anyURI
QName
NOTATION
string
decimal
primitive types
built-in types
normalizedString
integer
token
nonPositiveInteger
long
nonNegativeInteger
language
Name
NMTOKEN
negativeInteger
int
unsignedLong
positiveInteger
NCName
NMTOKENS
short
unsignedInt
ID
IDREF
ENTITY
byte
unsignedShort
IDREFS
ENTITIES
unsignedByte
derived types
derived by restriction
derived by list
derived by extension or restriction
ur types
built-in primitive types
built-in derived types
complex types
Erik Wilde – XML Schema
20
jax2004

Simple Type Restrictions

- Simple Types können durch *Restriction* von anderen Simple Types abgeleitet werden
  - der *Base Type* ist immer ebenfalls ein Simple Type
  - Wurzel dieser Hierarchie ist der `anySimpleType`
- Restrictions enthalten *Facets*
  - Facets sind durch vorgegebene Elemente definiert
    - es gibt 12 Arten von Facets
  - jede Restriction enthält 0-n Facets
    - Facets können wiederholt werden
  - wichtiges Werkzeug zur exakten Typ-Definition

Primitive Types Facets (I)

string	length, minLength, maxLength, pattern, enumeration, whiteSpace
boolean	pattern, whiteSpace
float	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
double	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
decimal	totalDigits, fractionDigits, pattern, whiteSpace, enumeration, maxInclusive, maxExclusive, minInclusive, minExclusive
duration	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
dateTime	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
time	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
date	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive

Primitive Types Facets (II)

gYearMonth	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
gYear	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
gMonthDay	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
gDay	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
gMonth	pattern, enumeration, whiteSpace, maxInclusive, maxExclusive, minInclusive, minExclusive
hexBinary	length, minLength, maxLength, pattern, enumeration, whiteSpace
base64Binary	length, minLength, maxLength, pattern, enumeration, whiteSpace
anyURI	length, minLength, maxLength, pattern, enumeration, whiteSpace
QName	length, minLength, maxLength, pattern, enumeration, whiteSpace
NOTATION	length, minLength, maxLength, pattern, enumeration, whiteSpace

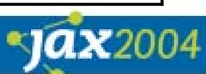

Patterns (Regular Expressions)

- Einschränkung von Simple Types
  - Restrictions mit dem `pattern` Element
- Beschränkung der lexikalischen Werte
- einfacher Aufbau der Ausdrücke
  - normale Zeichen: `"C& A"`
  - Zeichenklassen: `"\p{IsBasicLatin}"`
  - Zeichenmengen: `"[\p{IsBasicLatin}-[\d]]"`
  - Quantifiers: `"[a-zA-Z]{1,8}"`
  - Klammerausdrücke: `"(XML(\s+|-))?Schema"`
  - beliebige Kombination dieser Mechanismen

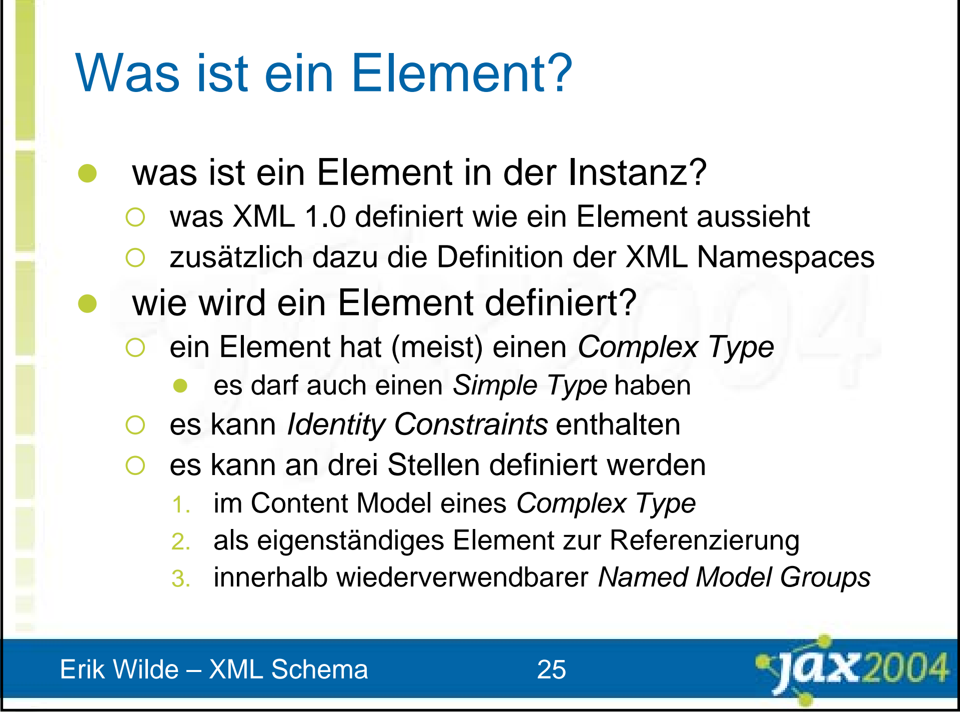
Was ist ein Element?
was ist ein Element in der Instanz?
was XML 1.0 definiert wie ein Element aussieht
zusätzlich dazu die Definition der XML Namespaces
wie wird ein Element definiert?
ein Element hat (meist) einen Complex Type
es darf auch einen Simple Type haben
es kann Identity Constraints enthalten
es kann an drei Stellen definiert werden
1. im Content Model eines Complex Type
2. als eigenständiges Element zur Referenzierung
3. innerhalb wiederverwendbarer Named Model Groups
Erik Wilde – XML Schema
25
jax2004

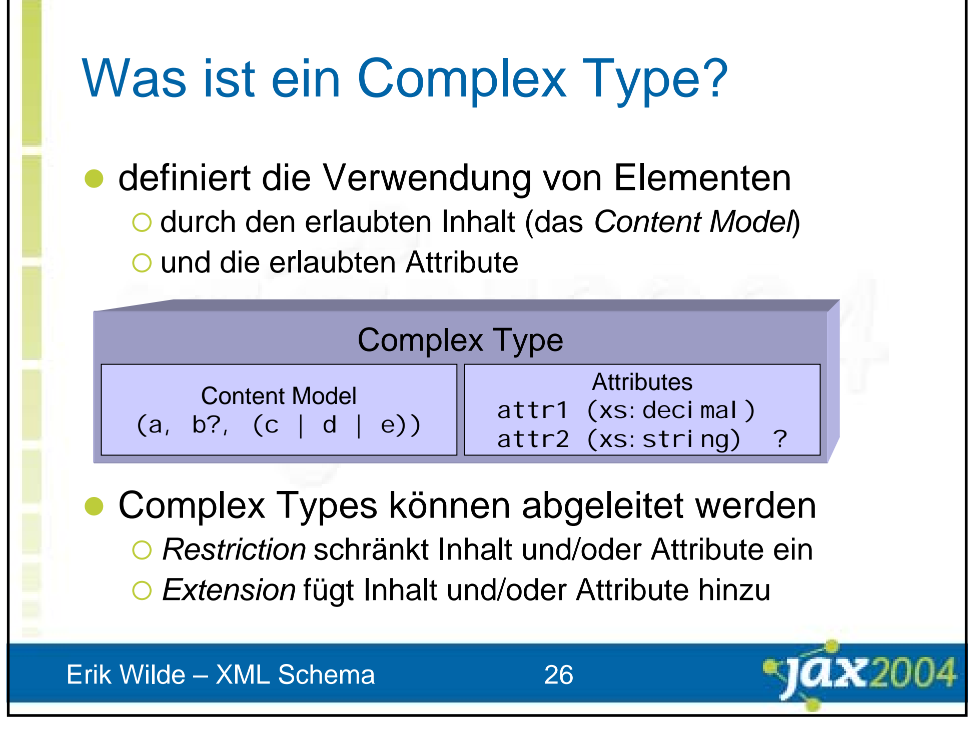
Was ist ein Complex Type?
definiert die Verwendung von Elementen
durch den erlaubten Inhalt (das Content Model)
und die erlaubten Attribute
Complex Type
Content Model
(a, b?, (c | d | e))
Attributes
attr1 (xs:decimal)
attr2 (xs:string) ?
Complex Types können abgeleitet werden
Restriction schränkt Inhalt und/oder Attribute ein
Extension fügt Inhalt und/oder Attribute hinzu
Erik Wilde – XML Schema
26
jax2004

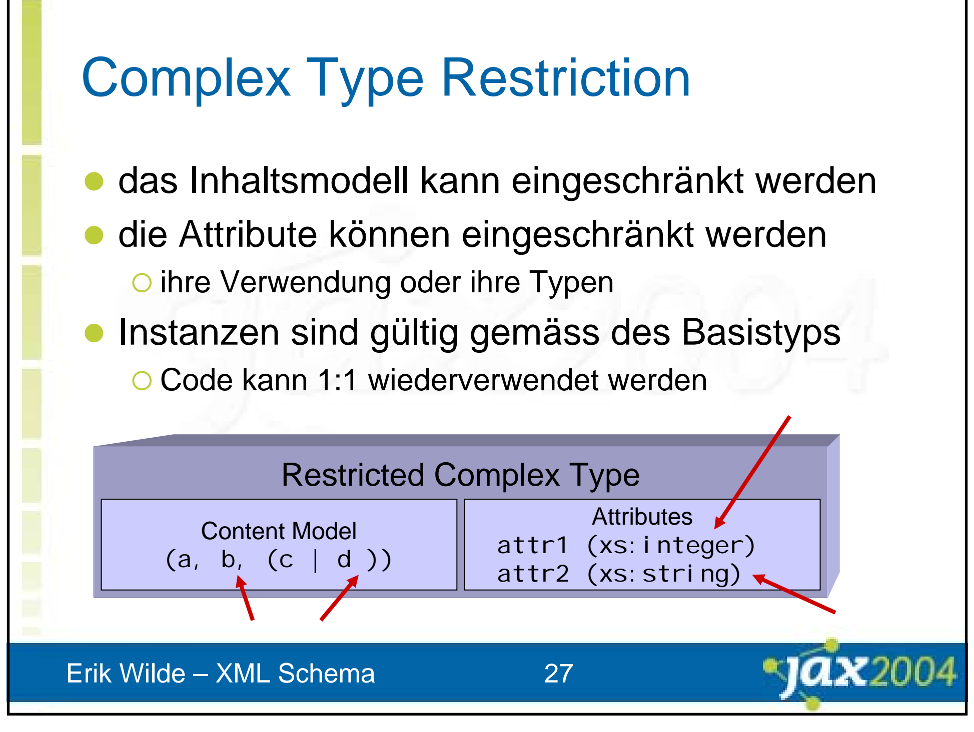
Complex Type Restriction
das Inhaltsmodell kann eingeschränkt werden
die Attribute können eingeschränkt werden
ihre Verwendung oder ihre Typen
Instanzen sind gültig gemäss des Basistyps
Code kann 1:1 wiederverwendet werden
Restricted Complex Type
Content Model
(a, b, (c | d))
Attributes
attr1 (xs:integer)
attr2 (xs:string)
Erik Wilde – XML Schema
27
jax2004

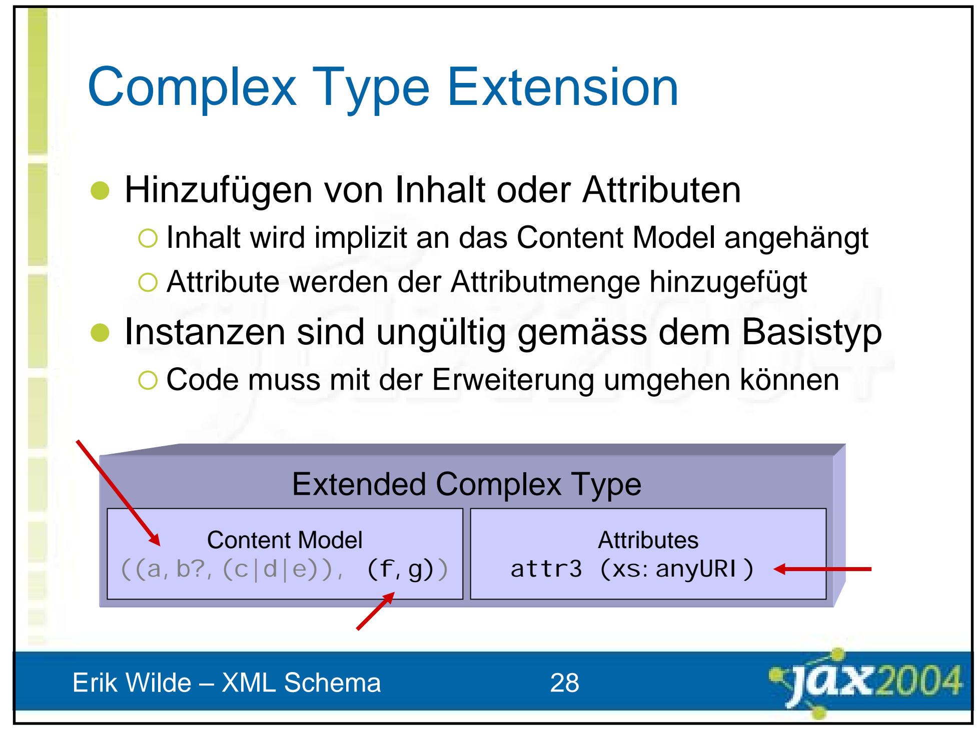
Complex Type Extension
Hinzufügen von Inhalt oder Attributen
Inhalt wird implizit an das Content Model angehängt
Attribute werden der Attributmenge hinzugefügt
Instanzen sind ungültig gemäss dem Basistyp
Code muss mit der Erweiterung umgehen können
Extended Complex Type
Content Model
((a, b?, (c|d|e)), (f, g))
Attributes
attr3 (xs:anyURI)
Erik Wilde – XML Schema
28
jax2004

Identity Constraints

- Erweiterung des ID/IDREF Konzepts
  - aber IDREFS wird nicht unterstützt
- bieten eine ganze Reihe von Vorteilen
  - belassen den *Typ* der Keys
    - ermöglicht eine Typ-Validierung der Keys
    - ermöglicht verschiedene Key Typen, z.B. Integers/Strings
  - beruhen auf *Wertegleichheit* ($+002_{integer} = 2_{integer}$)
  - ermöglichen Keys über *mehrere Felder*
  - ermöglichen *scoped* Keys (d.h. kontext-abhängig)
  - können auch auf *Elemente* angewendet werden
- sind etwas komplizierter zu benutzen

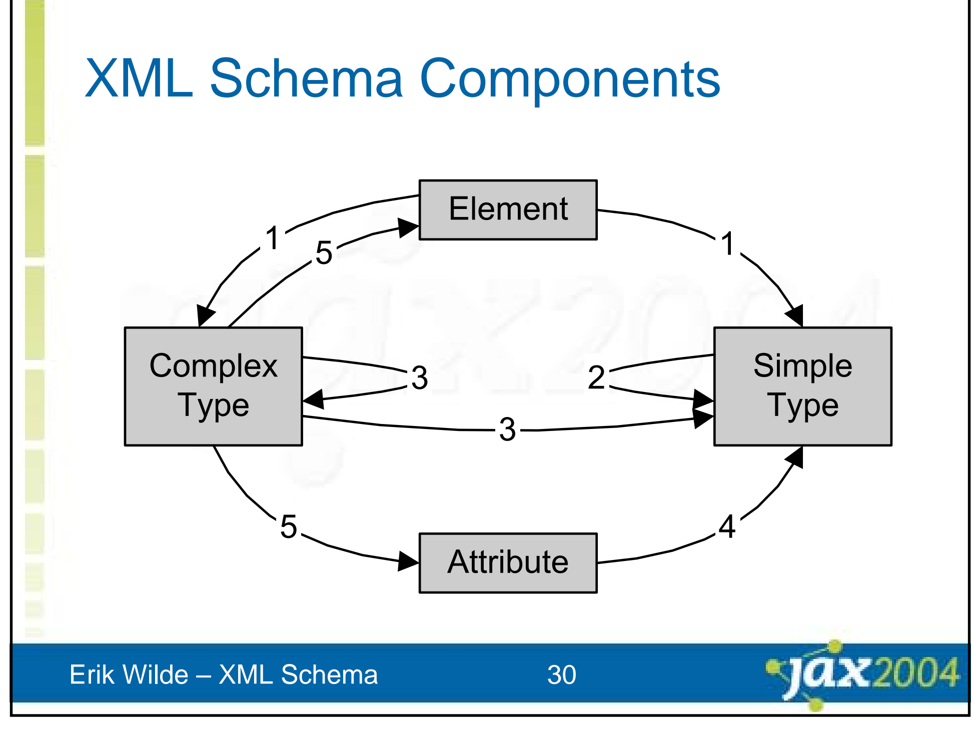

Erklärung der Zusammenhänge

1. *Elemente* werden durch Typen definiert
   - *Simple* und *Complex Types* sind erlaubt
2. *Simple Type* Ableitung von *Simple Types*
3. *Complex Type* Ableitung von Typen
   - *Simple* und *Complex Types* sind erlaubt
4. *Attribute* werden durch Typen definiert
   - ein Attribut hat immer einen *Simple Type*
5. *Complex Types* verwenden Elemente (*Content Model*) und Attribute

Alle XML Schema Components

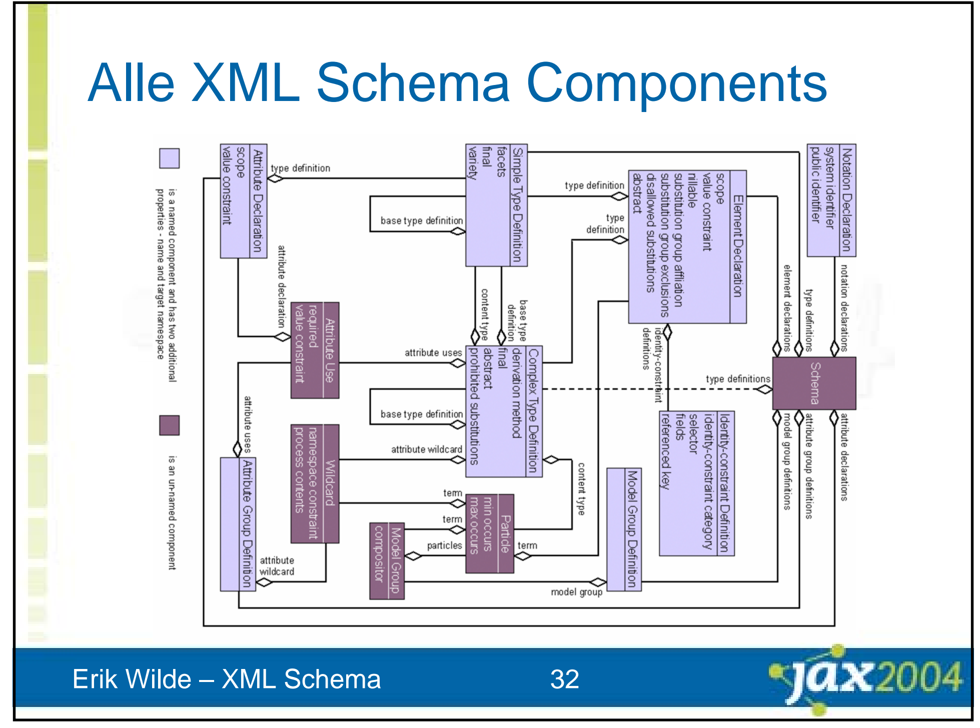

Lokale und Globale Deklarationen

- XML Schema unterstützt Wiederverwendung
  - von Typen (simple und komplexe Typen)
  - von Elementen und Attributen
- eine Modellierungsfrage des Schemas
  - keine Auswirkungen auf die Instanzen
  - wichtig für langlebige Schemas
    - Wiederverwendung von Schemateilen
    - Versionierung
- beide Konzepte sind orthogonal
  - alle Kombinationen sind möglich und sinnvoll

Erik Wilde – XML Schema 33

Orthogonalität der Konzepte

		Element/Attribut	
		Global	*Lokal*
Typen	*Global*	**1**: Element/Attribut und Typ sind benannt und wiederverwendbar	**2**: lokal definiertes Element/Attribut verwendet benannten Typ
Typen	*Lokal*	**3**: Element/Attribut ist wiederverwendbar und verwendet einen lokal definierten Typen	**4**: lokal definiertes Element/Attribut verwendet lokal definierten Typen

Erik Wilde – XML Schema 34 jax2004

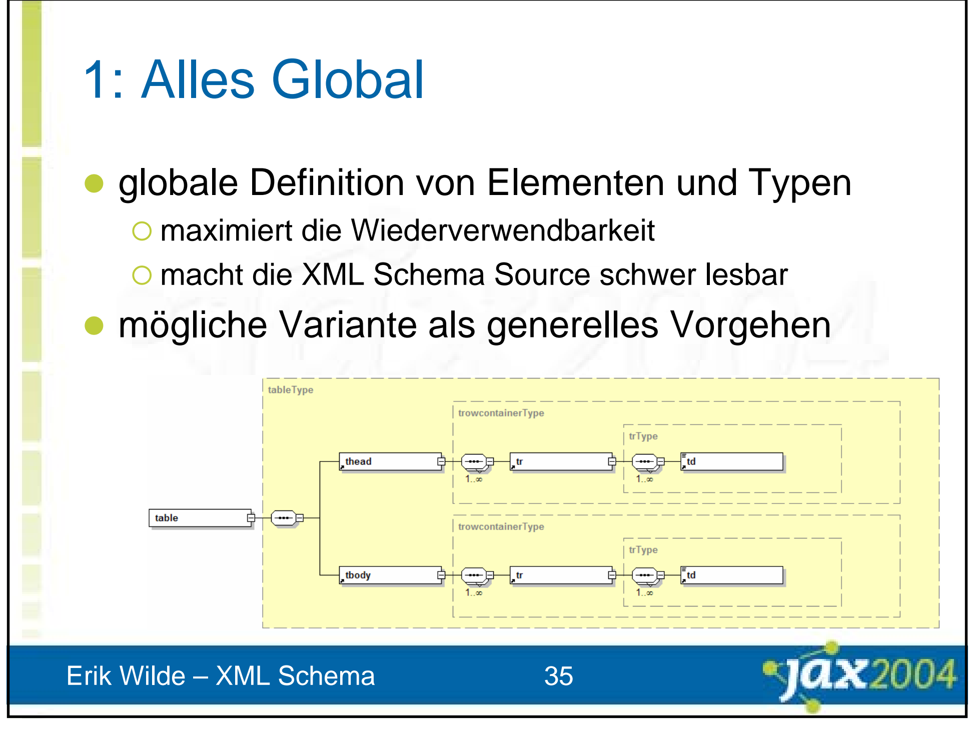
1: Alles Global
globale Definition von Elementen und Typen
maximiert die Wiederverwendbarkeit
macht die XML Schema Source schwer lesbar
mögliche Variante als generelles Vorgehen
tableType
trowcontainerType
trType
table
thead
tr
td
tbody
Erik Wilde – XML Schema
35
jax2004

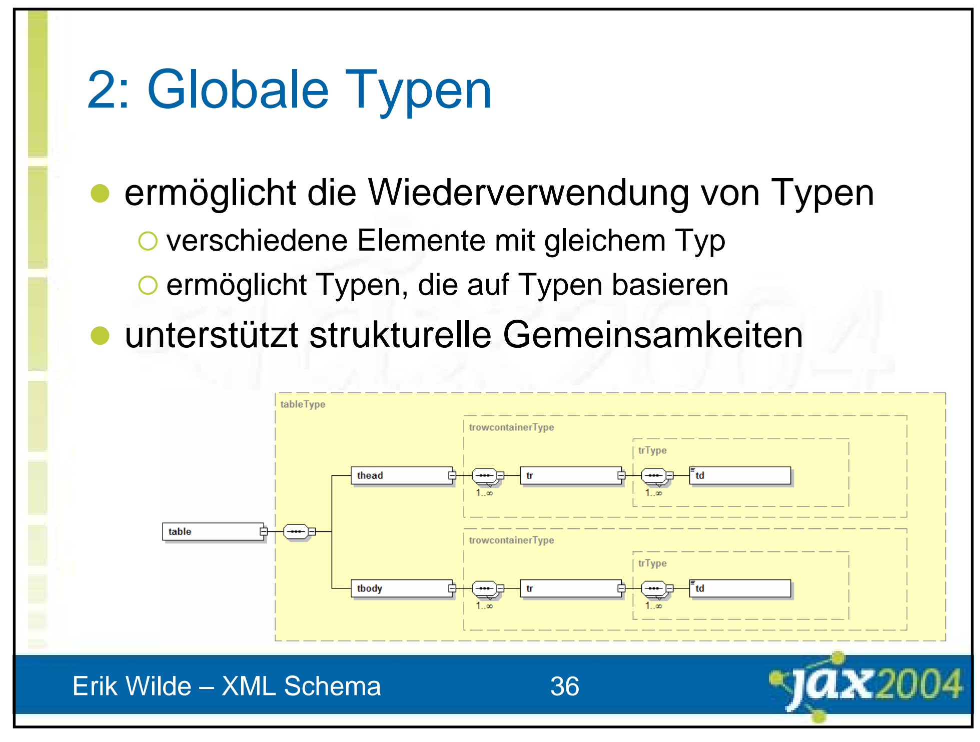
2: Globale Typen
ermöglicht die Wiederverwendung von Typen
verschiedene Elemente mit gleichem Typ
ermöglicht Typen, die auf Typen basieren
unterstützt strukturelle Gemeinsamkeiten
tableType
trowcontainerType
trType
table
thead
tr
td
tbody
Erik Wilde – XML Schema
36
jax2004

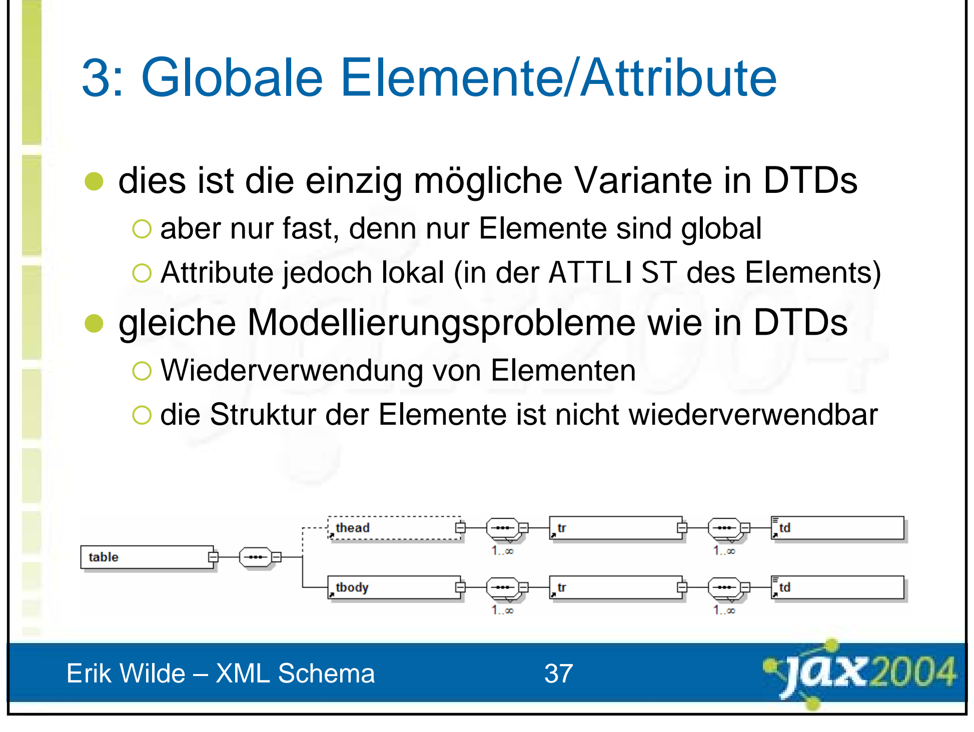
3: Globale Elemente/Attribute
dies ist die einzig mögliche Variante in DTDs
aber nur fast, denn nur Elemente sind global
Attribute jedoch lokal (in der ATTLIST des Elements)
gleiche Modellierungsprobleme wie in DTDs
Wiederverwendung von Elementen
die Struktur der Elemente ist nicht wiederverwendbar
table
thead
tbody
tr
td
1..∞
Erik Wilde – XML Schema
37
jax2004

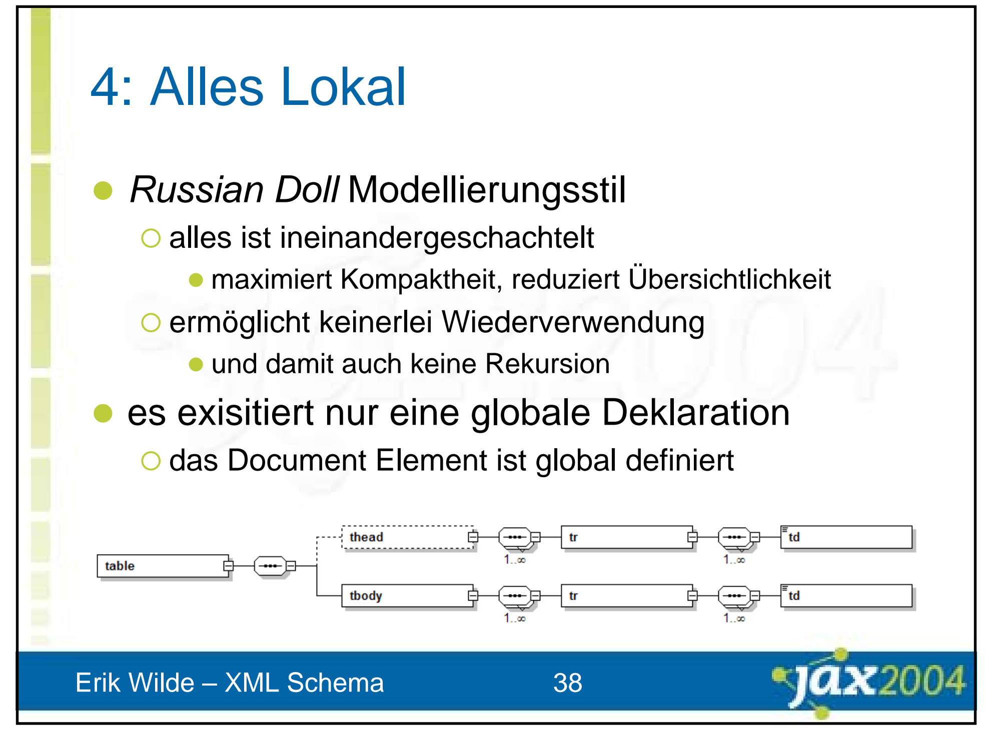
4: Alles Lokal
Russian Doll Modellierungsstil
alles ist ineinandergeschachtelt
maximiert Kompaktheit, reduziert Übersichtlichkeit
ermöglicht keinerlei Wiederverwendung
und damit auch keine Rekursion
es exisitiert nur eine globale Deklaration
das Document Element ist global definiert
table
thead
tbody
tr
td
1..∞
Erik Wilde – XML Schema
38
jax2004

Modellierungsfragen

- ist XML Schema meine Modellierungssprache?
  - falls ja, sollten Modellierungsregeln definiert werden
  - falls nein, wird es generiert aus dem Modell
- Modellierung für Wiederverwendung
  - Typbibliotheken für verschiedene XML Schemas
    - verschiedene Applikationen
    - verschiedene Versionen einer Applikation
  - Modellierungsrichtlinien sind wichtig
    - XML Schema bietet (zu) viele Freiheiten
    - Kontrolle z.T. über `final`, `block` und `abstract`
    - schlechte Modellierung kann sehr teuer werden

Implementierungsfragen

- XML Schema benutzt Typen
  - viele Mechanismen beruhen auf der Typebene
  - Programme sollten eher Typen als Namen verwenden
- XML 1.0 kennt keine Typen
  - in sehr limitierter Weise und nur für Attribute
- Typbasierung beeinflusst durch Modellierung
  - *Russian Doll* Schema braucht keine Typen
  - globale Typen sollten erkannt werden
    - abgeleitete Typen mit abgeleitetem Code verarbeiten
  - XML Schema kennt sogar Casting (*Type Substitution*)

XML Schema Support

- XML Schema Support in APIs
  - bisher kein etabliertes API für *PSVI Contributions*
  - bisher kein etabliertes API für *Schema Components*
- XML Schema Implementierungen
  - viele Parser implementieren XML Schema
  - kaum einer implementiert es komplett und korrekt
- XML Schema Test Suites vom W3C
  - `http://www.w3.org/2001/05/xmlschema-test-collection.html`
- IBM's *Schema Quality Checker (SQC)*
  - `http://www.alphaworks.ibm.com/tech/xmlsqc`

Zusammenfassung

- XML Schema als Basis für XML
  - führt Typen ein
  - ermöglicht bessere (restriktivere) Schemas als DTDs
- XML Schema ist ein komplexer Standard
  - viele Modellierungsvarianten
  - Schemas werden schnell unübersichtlich
- XML Schema Modellierung ist wichtig
  - Basis für Datenbanken und verteilte Applikationen
  - bisher sehr wenig Arbeiten in diesem Bereich