Inhalt:

8 XML

8.1 XML-Grundlagen

8.1.1 Einfaches XML-File erzeugen

XML-Files können mit einem Editor wie Notepad, speziellen XML-Editoren oder XML-Werkzeugen (wie z.B. XML-Spy) erstellt werden. Auch Visual Studio kann mit XML-Files gut umgehen.

New File → Categories: General → XML File.

Hinweis: Zum Kopieren von XML oder HTML Text über die Zwischenablage wählt man im Visual-Studio beim Einfügen "Paste as HTML".

Das folgende Beispiel zeigt ein XML-File:

```
<?xml version="1.0" encoding="utf-8"?>
<Figures>
  <Figure Id="F1">
    <Name>Circle1</Name>
    <Type>Circle</Type>
    <Size>20.5</Size>
  </Figure>
  <Figure Id="F2">
    <Name>Square</Name>
    <Type>Square></Type>
    <Size>20.5</Size>
  </Figure>
  <Figure Id="F3">
    <Name>Triangle</Name>
    <Type>Triangle</Type>
    <Size>34.6</Size>
  </Figure>
</Figures>
```

Der Aufbau erinnert an ein HTML-File. XML verwendet "Tags" um Elemente mit einer Anfangs- und Endmarke zu gruppieren. XML Editoren bieten meist komfortable Unterstützung bei der Erstellung, sei es durch automatische Vervollständigung oder durch spezielle Darstellungen der Struktur. Aber auch automatische Einrückungen machen die verschachtelte hierarchische Baumstruktur eines XML-Files sichtbar.

8.1.2 XML Syntax

XML-Tags sind nicht vordefiniert, man muss sie selber festlegen. Die Syntax für ein XML-File ist einfach.

Die erste Zeile im Dokument - die XML Deklaration - definiert die XML Version und die Codierung der Zeichen im File. Die nächste Zeile beschreibt das Wurzelelement (*root-element*) des Dokuments Jedes XML-Dokument muss genau ein Wurzelelement enthalten Dessen Name soll das Dokument charakterisieren, z.B. hier in der Form: "Dieses Dokument ist ein "Figures" Dokument". Die Elemente sind in einer Baumstruktur angelegt. Ein Element kann Kindelemente (child elements) enthalten. "Figure" ist ein Kindelement des Wurzelelements "Figures" und die Elemente "Name", "Type" und "Size" sind Kindelemente des "Figure"-Elements.

```
<root>
  <child>
    <subchild>.....</subchild>
```

```
  </child>
</root>
```

Verwendet man gute Namen für die XML-Tags, so ist ein XML File gut lesbar.

Einige wichtige Regeln:

- Alle XML Elemente müssen mit einem schließenden Tag (closing tag) abgeschlossen sein.
- XML-Tags sind groß-klein sensitiv.
- Alle XML Elemente müssen richtig verschachtelt sein.
- Ein XML Dokument darf nur einen Wurzelknoten haben.

Elemente haben einen Inhalt

Elemente können unterschiedlichen Inhalt haben. Zu einem XML Element gehört alles vom Start-Tag bis zum Ende-Tag ((einschließlich der Tags). Ein Element kann weitere Elemente, einfachen Inhalt oder gemischten Inhalt enthalten oder kann auch leer sein. Ein Element kann Attribute enthalten. Die Id's von Block und Parameter sind Attribute. Attribute müssen apostrophiert (*quoted*) sein. Es gibt keine Regel, ob Daten eines Elements als Subelemente oder als Attribute modelliert werden

Im Beispiel hat das "Figure"-Element weitere Elemente als Inhalt. Die Elemente "Name", "Type" und "Size" haben nur noch einfachen Inhalt (simple content or text content) weil diese Elemente nur noch Text enthalten.

`<Unit></Unit> oder <Unit/>`

ist ein Beispiel für ein leeres Element.

Beispiel:

```
<?xml version="1.0" encoding="UTF-8"?>
<root>
  <simplecontent>This is the content!</simplecontent>
  <mixedcontent>An example for mixed element content. First text and
  then a nested element<nested_element>Content of nested
  element</nested_element>
  </mixedcontent>
  <emptycontent></emptycontent>
  <emptycontent/>
  <element at1="Attribute 1" at2="Attribute 2"></element>
  <!-- This is a comment -->
</root>
```

Elemente versus Attribute

Man kann die eigentlichen Daten in Elementen oder Attributen unterbringen.

Beispiel:

```
<person sex="female">
  <firstname>Anna</firstname>
  <lastname>Smith</lastname>
</person>

<person>
  <sex>female</sex>
  <firstname>Anna</firstname>
  <lastname>Smith</lastname>
</person>
```

Im ersten Beispiel ist `sex` ein Attribut. Im zweiten ist `sex` ein Kind-Element. Die Information ist dieselbe.

Es gibt breite Diskussionen, aber keine Regel über die Verwendung von Elementen und/oder Attributen. Im Zweifelsfall entscheide ich mich eher für Elemente.

8.1.3 XML Validierung und Schemas

8.1.3.1 "Wohl geformte" ("*Well Formed*") XML Dokumente

Ein "wohl geformtes" XML Dokument erfüllt die XML Syntax. XML-Editoren beachten diese Syntax, bzw. erlauben eine Überprüfung der Syntax.

XML-SPY

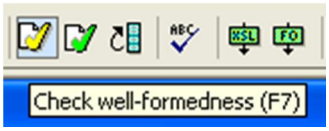

Wichtig: XML Applikationen brechen die Bearbeitung für ein nicht wohl geformtes XML Dokument in der Regel ab. Dies ist in den W3C XML Spezifikationen so festgelegt: "*A program should not continue to process an XML document if it is not well-formed. The reason is that XML software should be easy to write, and that all XML documents should be compatible.*"

8.1.3.2 "Gültige" XML Dokumente

Ein "gültiges" (*valid*) XML Dokument ist ein wohl geformtes XML Dokument, das zusätzlich einer Dokument Type Definition (DTD) oder einem Schema entspricht. Sowohl DTD's als auch Schemas definieren die erlaubte Struktur als auch die Daten der Elemente. Hier werden nur (die wichtigeren) Schemas besprochen.

XML Schemas werden ebenfalls in einem XML File definiert. Einfacher erstellt man Schemas jedoch mit einem entsprechenden Werkzeug.

8.1.3.3 XML Schemas

Ein Schema beschreibt die erlaubte Struktur eines XML Dokuments. Im Detail bedeutet das hauptsächlich:

- die Struktur des XML Dokumentes
- die Attribute eines Elements
- den Datentyp der Textknoten
- Ob Elemente oder Attribute vorhanden sein müssen oder optional sind

Beispiel:

Schema zu unserem Beispiel mit einer Liste von Figuren:

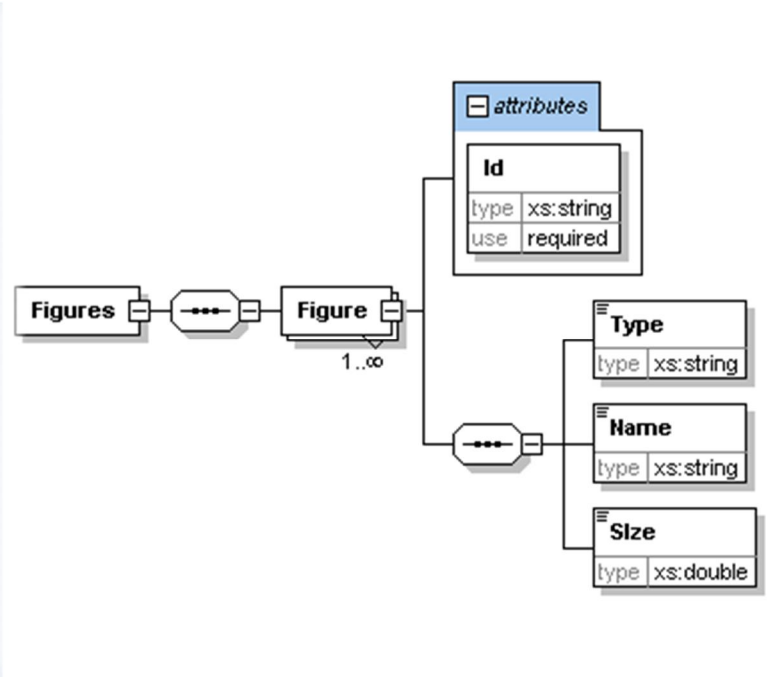

XML-Spy verwendet eine geschickte, gut lesbare Darstellung:

Der Wurzelknoten `Figures` enthält eine Sequenz aus `Figure` Elementen. Die Zahl der `Figure` Elemente ist mindestens 1 und nach oben unbegrenzt. Die Endknoten enthalten die eigentlichen Daten. Für den Text dieser Knoten sind einfache Datentypen definiert. Die Liste der Datentypen umfasst alle aus den Programmiersprachen bekannten Typen. Der Inhalt des Elements `(InnerText)` ist dann jedoch immer eine Zeichenkette. Der Datentyp `xs:double` z.B. erlaubt die üblichen Darstellungen eines Double-Wertes inklusive den Mustern `INF`, `-INF` und `NaN` für +∞, -∞ und "nicht definiert".

Man kann selber Datentypen definieren. Einfachen Typen basieren meist auf einem der vordefinierten Typen und definieren Einschränkungen zu diesem Typ. Schon unser einfaches Schema kann diese Möglichkeiten sinnvoll verwenden. Als `Id` sollen z.B. nur Wörter verwendet werden dürfen, die mit einem Buchstaben beginnen und dann nur noch Buchstaben und/oder Zahlen enthalten. Schemas sind selber auch wieder XML-Dateien. In Textform lautet die Definition des Typs `tId`:

```
<xs:simpleType name="tIdentifier">
    <xs:restriction base="xs:string">
      <xs:pattern value="[a-zA-Z]{1}[a-zA-Z0-9_]*"/>
    </xs:restriction>
  </xs:simpleType>
```

Die Namen der Tags und die vordefinierten Datentypen sind hier inklusive einem Namensraum (Namespace) xs angegeben, der am Beginn des Dokuments definiert ist. Der voll qualifizierte Name eines Elements ist bei Verwendung eines Namensraumes `namespace:name`.

Der Typ `tType` definiert für den erlaubten Inhalt des Typ-Elements nur die in einer Aufzählung genannten Wörter.

```
<xs:simpleType name="tType">
  <xs:restriction base="xs:string">
    <xs:enumeration value="Circle"/>
    <xs:enumeration value="Square"/>
    <xs:enumeration value="Triangle"/>
  </xs:restriction>
</xs:simpleType>
```

Für den Wert `Size` ist noch ein Typ definiert, der nur positive Werte zulässt.

```
<xs:simpleType name="tReal">
  <xs:restriction base="xs:double">
    <xs:minInclusive value="0"/>
  </xs:restriction>
</xs:simpleType>
```

Ein komplexer Datentyp erlaubt die Zusammenfassung von mehreren Knoten und Subknoten zu einem neuen Typ. Im folgenden Beispiel sind die Elemente für eine `Figure` als neuer Typ `tFigure` definiert.

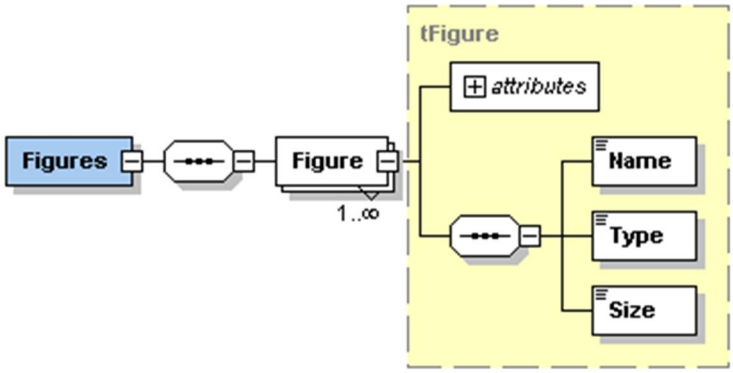

8.1.3.4 Validieren von XML-Files

Gute XML-Editoren können ein File gegen ein zugehöriges Schema validieren.

8.2 XML Files anzeigen

8.2.1 Reines XML

XML Dokumente können mit dem Internet-Explorer oder einem anderen Browser angezeigt werden. Nach einer typischen Installation ist der IE für XML-Files zuständig. Das Dokument wird mit farbigen Tags und durch Einrückungen strukturiert angezeigt. Man kann Elemente expandieren oder kollabieren.

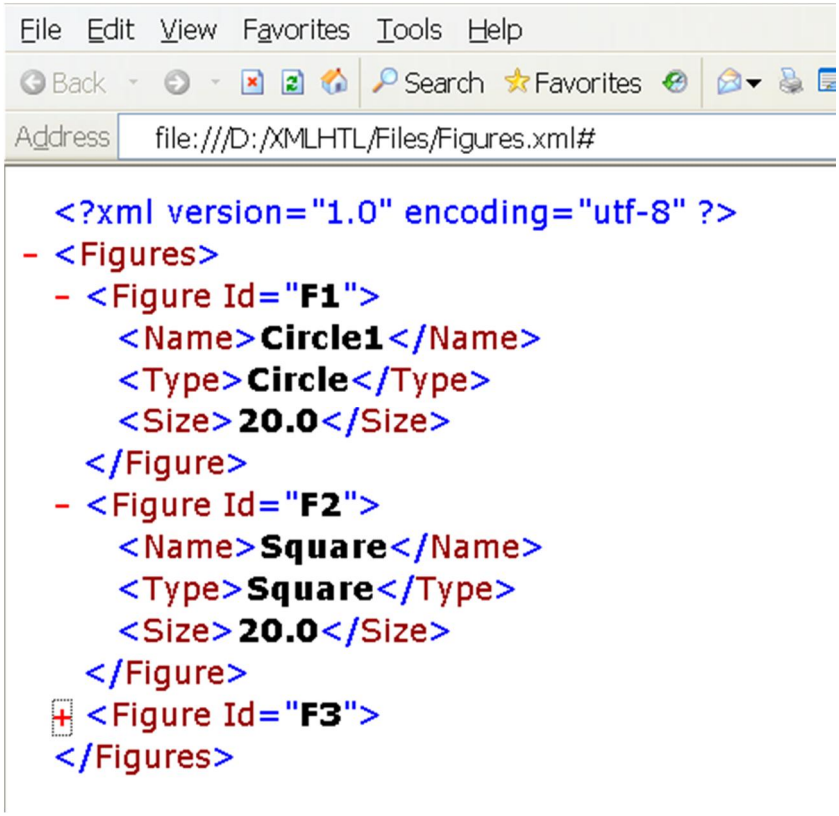

Will man das File editieren so geht das nur über Ansicht → Quelltext.

8.2.2 CSS Style-Sheet

Der "*Cascading Style Sheets*" Standard definiert eine Sprache zur Definition von Formateigenschaften für HTML oder XML Tags. Man kann CSS Style Sheets einem XML File zuordnen. Der Browser verwendet dann die Definitionen im Style Sheet um den Text-Inhalt des XML Files anzuzeigen. Ein Beispiel finden Sie unter http://www.w3schools.com/xml/xml_display.asp

8.2.3 XSL

XSL ist die Abkürzung für eXtensible Stylesheet Language. Dieser Standard dient speziell der Darstellung von XML Dokumenten. XSL ist ein sehr mächtiges Konzept und kann verwendet werden um XML Dokumente in beliebige andere Dokumente umzuwandeln, z.B. in HTML-Files, PDF Files, SVG Files, Programmcode und vieles mehr.

8.3 XPath

XPath stellt eine Syntax zur Auswahl von Teilen eines XML-Dokuments dar. XPath ist für alle Techniken, die im Zusammenhang mit XML verwendet werden, eine wichtige Grundlage. XPath betrachtet ein XML-Dokument als einen Baum mit Knoten. Dieser Baum ist sehr ähnlich dem DOM-Baum. Man unterscheidet verschiedene Arten von Knoten:

- Wurzelknoten
- Elementkonten
- Attributknoten
- Textknoten
- Kommentarknoten
- Verarbeitungsanweisungen
- Namensraumknoten

Zur Auswahl von Dokumentteilen kann man absolute und relative Pfadangaben machen.

Beispiele für XPath Ausdrücke und der damit erfassten Knotenmenge für das Figures Dokument.

```
<?xml version="1.0" encoding="utf-8"?>
<Figures>
  <Figure Id="F1">
    <Name>Circle1</Name>
    <Type>Circle</Type>
    <Size>20.0</Size>
  </Figure>
  <Figure Id="F2">
    <Name>Square</Name>
    <Type>Square</Type>
    <Size>20.0</Size>
  </Figure>
  <Figure Id="F3">
    <Name>Triangle</Name>
    <Type>Triangle</Type>
    <Size>34.6</Size>
  </Figure>
</Figures>
```

XPath	Bemerkung	Knotenmenge
/	der Wurzelknoten Er enthält das gesamte Dokument. Er enthält das Element `Figures` und ist nicht das Element `Figures` selbst.	
/`Figures`		`Figures`
/`Figures`/*	Alle Kinder des `Figures` Knoten	`Figure` Id=F1 `Figure` Id=F2 `Figure` Id=F3
/`Figures`/*[@Id='F2']	Auswahl eines Kindelements mit einem bestimmten Wert des `Id` Attributes	`Figure` Id=F2

Nun sei <`Figures`> das aktuell ausgewählte Element und die folgenden Angaben sind relative Pfade.

`*[@Id='F2']`	Auswahl eines Kindelements mit einem bestimmten Wert des `Id` Attributes	`Figure Id=F2`
`Figure[2]`	Auswahl über einen Index (beginnt bei 1)	`Figure Id=F2`
`Figure[2]/Name`	der Elementknoten Name des zweiten Figure Knotens	`Name`
`Figure[2]/Name/text()`	Der Text des Elements	`"Square"`
`.`	der aktuelle Knoten	
`..`	der Elternknoten	

In den Beispielen wurde die abgekürzte Syntax verwendet. Die nicht abgekürzte Syntax verwendet Schlüsselwörter wie `child`, `parent`, `ancestor-or-self` um insgesamt 13 so genannte Achsen auszuwählen.

Beispiele ausgehend vom aktuellen Knoten (=Kontextknoten) Name des dritten `Figure` Elements.

abgekürzte Schreibweise	volle Schreibweise	Resultat
.	`self::*`	`Name`
..	`parent::*`	`Figure`
`ancestor`::*	Alle Elternknoten des Kontextknotens	`Figure` `Figures`

8.4 XML mit C# und .NET

XML ist ein wesentlicher Teil des Konzeptes von .NET und den .NET Sprachen. Konfigurationsdateien und die Ressource Dateien (*.resx) sind XML-Dateien, es gibt die

Möglichkeit Objekte mit nur minimalem Programmieraufwand in XML Dateien zu serialisieren. Zudem unterstützt das Framework praktisch alle Aspekte von XML.

In diesem Rahmen ist es sinnvoller, statt vorgefertigte (und unflexiblen) Framework Lösungen zu besprechen, grundlegende Techniken zu zeigen.

Sowohl für die Erzeugung als auch für das Lesen von XML Dokumenten hat man grundsätzlich zwei Möglichkeiten.

- Sequenzielle Verfahren (`XmlWriter`, `XmlReader`)
- DOM (`XmlDocument`)

8.4.1 XmlWriter

Das sequenzielle Verfahren eignet sich besonders zur Serialisierung eines Dokuments, das intern nicht schon als `XmlDocument`, sondern durch eine typische (oft hierarchische) Sammlung von Objekten repräsentiert wird.

Für das Beispiel mit den geometrischen Figuren dient eine von `ArrayList` abgeleitete Klasse `FigureCollection` zur Verwaltung einer Sammlung von Figuren. Es ist nahe liegend in dieser Klasse eine Methode zur Serialisierung in eine Xml-Datei zur Verfügung zu stellen.

Ab .NET 2.0 verwendet man für die XML-Serialisierung einen `XmlWriter`, der wiederum seine Einstellungen aus einem `XmlWriterSettings` Objekt holt. Der `XmlWriter` selber wird durch eine statische Methode `XmlWriter.Create` erzeugt.

```
public void SerializeToXMLFile(string fileName)
{
  XmlWriter xw;
  XmlWriterSettings settings = new XmlWriterSettings();
  settings.Indent = true;
  settings.IndentChars = "\t";

  // Create a XmlWriter.
  xw = XmlWriter.Create(fileName, settings);

  xw.WriteStartDocument();
  xw.WriteStartElement("Figures");    // <Figures>

  for (int i = 0; i < base.Count; i++)
  {
    Figure f = (Figure) base[i];
    xw.WriteStartElement("Figure");   // <Figure>
    xw.WriteAttributeString("Id", f.Id);
    xw.WriteElementString("Type", f.Type);
    xw.WriteElementString("Size", XmlConvert.ToString(f.Size));
    xw.WriteElementString("Color", XmlConvert.ToString(f.ColorNr));
    xw.WriteEndElement();             // </Figure>
  }
```

```
  xw.WriteEndElement();                // </Figures>
  xw.WriteEndDocument();

  xw.Close();

  //

}
```

Der Code bedarf wohl kaum einer weiteren Erläuterung.

Die Serialisierung eines Objektes könnte auch im Objekt selber codiert werden. Der Methode übergibt man als Argument eine Referenz auf einen `XmlWriter`. Eigentlich ist das die Lösung die dem OOP Ansatz noch besser entspricht.

8.4.2 Lesen über `XmlDocument` (DOM)

Für das Lesen ist der einfachste Ansatz die Verwendung von XmlDocument. Ein `XmlDocument` kann mit einer einzigen Anweisung mit dem Inhalt eines Xml Files gefüllt werden. Dann kann man beliebig im Knotenbaum navigieren und den Inhalt lesen. Die wichtigsten Methoden sind dabei

`SelectSingleNode` und `SelectNodes`.

Zur Auswahl eines Knotens oder einer Knotenmenge verwendet man XPath Ausdrücke.

```
public void ReadUsingDom (string fileName)
{
  XmlDocument xmlDoc = new XmlDocument();

  xmlDoc.Load(fileName);

  XmlNode node;
  node = xmlDoc.SelectSingleNode(@"/Figures");
  if (node == null)
    return;

  base.Clear(); // Remove all itmes from the collection

  XmlNodeList nodeList = node.SelectNodes("Figure");
  foreach (XmlNode child in nodeList)
  {
    Figure f;
    XmlNode testNode;
    string type, sRead;
    testNode = child.SelectSingleNode("Type");
    type = testNode != null ? testNode.InnerText : "Undefined";
    switch (type)
    {
      case "Circle":
        f = new Circle();
        break;
      case "Square":
        f = new Square();
        break;
      case "Triangle":
        f = new Triangle();
        break;
```

```
      default:
        f = null;
        break;
    }

    if (f == null) continue;

    // get the properties and set the values

    testNode = child.SelectSingleNode("@Id");
    sRead = testNode != null ? testNode.InnerText : "UndefinedId";
    f.Id = sRead;

    testNode = child.SelectSingleNode("Size");
    sRead = testNode != null ? testNode.InnerText : "100.0";
    f.Size = (float) XmlConvert.ToDouble(sRead);

    testNode = child.SelectSingleNode("Color");
    sRead = testNode != null ? testNode.InnerText : "0";
    f.ColorNr = XmlConvert.ToInt32(sRead);

    base.Add(f);

    Debug.WriteLine(String.Format("{0} {1} {2:f3}",
      type, f.Id, f.Size));
  }

  xmlDoc.RemoveAll();
  xmlDoc = null;
}
```

8.4.3 XmlReader

Die Arbeit mit den sequentiellen Verfahren ist etwas gewöhnungsbedürftig. Der folgende Code verwendet die Methode `Read` und reagiert je nach Typ und Name des gelesenen Knotens auf den aktuellen Knoten im Eingabestrom. `Read` liest jeweils den nächsten Knoten.

```
public void SerializeFromXmlFile1 (string fileName)
{
  XmlReaderSettings settings;
  settings = new XmlReaderSettings();
  // use all the default settings

  XmlReader xr = XmlReader.Create(fileName, settings);

  base.Clear();

  string msg;
  string id = "";
  string type = "Undefined";
  Figure f = null;
  string sRead = "";

  xr.MoveToContent();
  while (xr.Read())
  {
    if (xr.NodeType == XmlNodeType.Element)
```

```
    {
      string name = xr.Name;
      switch (xr.Name)
      {
        case "Figure":
          id = xr.GetAttribute("Id");
          break;
        case "Type":
          type = xr.ReadString();
          switch (type)
          {
            case "Circle":
                f = new Circle();
                break;
            case "Square":
                f = new Square();
                break;
            case "Triangle":
                f = new Triangle();
                break;
            default:
                f = null;
                break;
          }
          f.Id = id;
          base.Add(f);
          break;
        case "Size":
          sRead = xr.ReadString();
          f.Size = (float) XmlConvert.ToDouble(sRead);
          break;
        case "Color":
          sRead = xr.ReadString();
          f.ColorNr = XmlConvert.ToInt32(sRead);
          break;
        default:
          sRead = "";
          break;
      }
      msg = String.Format("{0} {1}", name, sRead);
      Debug.WriteLine(msg);
    }
  }
  xr.Close();
}
```

Sowohl beim Schreiben als auch beim Lesen werden die `XmlConvert` Methoden verwendet um beim Schreiben den Inhalt der Textknoten zu erzeugen und beim Lesen die Textdarstellung der Daten wieder in C# Datentypen umzuwandeln. Besonders beim Lesen ist zu beachten, dass nicht passende Daten zu einer Exception führen, die man abfangen muss.

Das nächste Beispiel zeigt eine Technik, die einer Art Umkehrung der Technik beim Schreiben des Dokuments entspricht. Der XMLTextReader liest die Datei sequentiell.

```
public bool SerializeFromXmlFile2(string fileName)
{
  bool success = true;
```

```
string elementName;
string elementString;

XmlTextReader r;

r = new XmlTextReader(fileName);

// 0        1         2
// 12345678901234567890123456789012345678901234567890
//<?xml version="1.0" encoding="utf-8"?>
//<Figures>
//    <Figure Id="Circle0">
//        <Type>Circle</Type>
//        <Size>30</Size>
//        <Color>1</Color>
//    </Figure>
//    ...
//</Figures>

base.Clear();

try
{
  ShowXmlReaderStatus(r);           // position = line 0, column 0
  r.ReadStartElement("Figures");
  // position = 2, 10 (end of start element <Figures>
  // MoveToContent()
  // It skips over nodes of the following type:
  // ProcessingInstruction, DocumentType, Comment,
  // Whitespace, or SignificantWhitespace.
  // ReadStartElement includes a MoveToContent()
  r.MoveToContent();     // pos = 3, 3 (Start of element <Figure>
  ShowXmlReaderStatus(r);
  while (r.Name == "Figure")
  {
    Figure f = null;
    string id;
    // read the "Id" attribut
    r.MoveToFirstAttribute();
    id = r.Value;

    r.ReadStartElement();     // pos = end of element tag Figure
    ShowXmlReaderStatus(r);

    // read the child elements: Type, Size, Color
    r.MoveToContent();        // pos = before the <Size> element
    elementName = r.LocalName;
    elementString = r.ReadElementString();
    Debug.WriteLine(string.Format("Name = {0} Content = {1}",
      elementName, elementString));
    switch (elementString)
    {
      case "Circle":
        f = new Circle();
        break;
      case "Square":
```

```
            f = new Square();
            break;
          case "Triangle":
            f = new Triangle();
            break;
          default:
            f = null;
            break;
        }
        f.Id = id;

        r.MoveToContent();   // pos = before the <Size> element
        elementName = r.LocalName;
        // .NET 1.x
        elementString = r.ReadElementString();
        ShowXmlReaderStatus(r);
        Debug.WriteLine(string.Format("Name = {0} Content = {1}",
          elementName, elementString));
        f.Size = (float)XmlConvert.ToDouble(elementString);

        r.MoveToContent();
        elementName = r.LocalName;
        // .NET 2.0
        f.ColorNr = r.ReadElementContentAsInt();
        Debug.WriteLine(string.Format("Name = {0} Content = {1:d}",
          elementName, f.ColorNr));

        base.Add(f);

        r.ReadEndElement();  // moves to end of </Figure>
        r.MoveToContent();
      }

      r.ReadEndElement();

    }
    catch (XmlException e)
    {
      Debug.WriteLine(e.Message);
      success = false;
    }
    return success;
}

void ShowXmlReaderStatus(XmlTextReader r)
{
    string s = String.Format("{0} ({1}) Position = {2},{3}",
      r.LocalName, r.NodeType.ToString(), r.LineNumber,
      r.LinePosition);
    Debug.WriteLine(s);
}
```

8.4.4 Validierung im Programm

Um ein XML File in einem Programm zu validieren, muss man das Schema in eine `XmlSchemaCollection` aufnehmen und das `XmlDocument` über einen `ValidierungsReader` lesen. Ein Eventhandler wird dann aufgerufen, wenn ein Fehler festgestellt wird.

```
public bool ReadXmlFile(string xmlFileName, string schemaFileName)
{
  xmlTextReader = new XmlTextReader(xmlFileName);
  XmlSchemaCollection schemas = null;

  schemas = new XmlSchemaCollection();
  schemas.Add(null, schemaFileName);

  XmlValidatingReader validationReader =
    new XmlValidatingReader(xmlTextReader);
  validationReader.Schemas.Add(schemas);

    // Set the validation event handler
    validationReader.ValidationEventHandler +=
      new ValidationEventHandler(ValidationCallBack);

    xmlDoc.Load(validationReader);
    validationReader.Close();
    xmlTextReader.Close();
    …
}
```

```
void ValidationCallBack (object sender, ValidationEventArgs args)
{
  // split the sentences (delimiter is '.')
  // in the message into lines of text.
  Regex splitToLines = new Regex(@"\. ");
  string [] messageLines = splitToLines.Split(args.Message);
  int n = messageLines.Length;
  string description = "";
  // do not use the last line (contains the file name)
  for (int i = 0; i < n - 1; i++)
  {
    messageLines[i] += ".";
    description += messageLines[i] + " ";
  }
  // get the current line and column from the xml reader
  string message;
  XmlSchemaException e = args.Exception;
  message =
    String.Format("Error in line {0}, column {1} ({2} {3} {4})",
    e.LineNumber, e.LinePosition, xmlTextReader.Name,
    xmlTextReader.Value, description);
  Debug.WriteLine(message);
  errors.Add(message);

}
```

8.5 XSLT

XSL ist mehr als eine *Style Sheet Language*.

XSL besteht aus drei Teilen:

- XSLT ist eine Sprache zur Transformation von XML Dokumenten
- XPath ist eine Sprache um Teile eines XML Dokument auszuwählen, bzw. in einem XML Dokument zu navigieren
- XSL-FO ist eine Sprache um XML Dokumente zu formatieren

XSL ist ein Konzept, das es ermöglicht XML nach XML, XHTML, Text etc. zu transformieren, es erlaubt die Filterung und Sortierung von XML Daten, eine datenabhängige Formatierung von XML Daten.

Die Quelle einer Transformation ist immer ein XML Dokument. Der XSLT Prozessor holt sich die Instruktionen aus einem XSLT File und schickt das Resultat der Transformation auf einen Ausgabestrom.

Ein XML-File kann das XSLT File als "*processing instruction*" definiert haben:

<?xml-stylesheet type="text/xsl" href="ToHtml.xslt"?>

Wird ein XML-File mit einer solchen Anweisung von einem Browser geladen, so wird der XSLT Prozessor aufgerufen und das Resultat der Transformation angezeigt.

Die meisten XSLT Prozessoren sind auch als ausführbares Programm in einer Kommandozeilenversion verfügbar. Z.B. kann man den Microsoft XSLT Prozessor folgendermaßen verwenden:

```
C:\>msxsl -?
Microsoft (R) XSLT Processor Version 4.0
Usage: MSXSL source stylesheet [options] [param=value...] [xmlns:prefix=uri...]
Options:
    -?              Show this message
    -o filename     Write output to named file
    -m startMode    Start the transform in this mode
    -xw             Strip non-significant whitespace from source and stylesheet
    -xe             Do not resolve external definitions during parse phase
    -v              Validate Dokuments during parse phase
    -t              Show load and transformation timings
    -pi             Get stylesheet URL from xml-stylesheet PI in source Dokument
    -u version      Use a specific version of MSXML: '2.6', '3.0', '4.0'
    -               Dash used as source argument loads XML from stdin
    -               Dash used as stylesheet argument loads XSL from stdin
```

`Msxsl` findet man über Google leicht zum Download, er funktioniert allerdings nur mit der Version 4 der Microsoft Core XML Services (MSXML). Die Version 3 wird mit dem Internet Explorer installiert.

8.5.1 Transformation eines XML Dokuments in ein Textfile.

Wir verwenden wieder unser XML Beispiel mit einer Liste von Figuren. XSLT Transformationen sind ebenfalls XML-Files und können mit Werkzeugen wie XML-Spy oder mit dem Visual-Studio erstellt werden.

Je nach Werkzeug wird dann z.B. gleich mehr oder weniger des äußeren Fragments eines XSLT Files erzeugt.

```
<?xml version="1.0" encoding="UTF-8"?>
<xsl:stylesheet version="1.0"
    xmlns:xsl="http://www.w3.org/1999/XSL/Transform">
</xsl:stylesheet>
```

Mit der Output-Anweisung wird das Ausgabeformat festgelegt:

<xsl:output method="text" encoding=""ISO-8859-1"/>

Es ist einleuchtend, dass wir für eine Transformation zwei Dinge benötigen:

- Kommandos um Ausgaben zu erzeugen, d.h. auf den Ausgabestrom zu schreiben.
- Kommandos, um Elemente im XML Dokument auszuwählen.

Ein XSLT Style Sheet ist ein XML Dokument. Die Anweisungen für den XSLT Prozessor sind Elemente aus dem xsl: Namensraum.

Zuerst liest der XSLT Prozessor das Style Sheet und konvertiert es in eine interne Datenstruktur, so dass er schnell findet, was er braucht.

Dann muss er das Dokument lesen und ebenfalls in einer Datenstruktur, einem Baum abbilden.

Für jeden Verarbeitungsschritt ist ein so genannter Kontext definiert. Dies ist der aktuelle Verarbeitungsknoten oder eine Liste von Knoten. Zu Beginn ist der Kontext die Wurzel des XML Dokuments. Dann arbeitet der Prozessor nach folgendem Prinzip:

Solange der Kontext Knoten enthält führe aus:
Hole den nächsten Knoten des Kontexts. Gibt es Vorlagen (*templates*) die zu diesem Knoten passen? Falls ein oder mehrere Vorlagen passen, verwende die richtige und verarbeite sie.

Beachte, dass dies ein rekursives Verarbeitungsmodell ist.

Das folgende Beispiel transformiert unser Musterdokument XmlTestDokument.xml in ein Textfile.

```
<?xml version="1.0" encoding="UTF-8"?>
<xsl:stylesheet version="1.0"
  xmlns:xsl="http://www.w3.org/1999/XSL/Transform">

<xsl:output method="text" encoding="ISO-8859-1"/>
```

```
<xsl:template match="/">
  <xsl:call-template name="Text"></xsl:call-template>
  <xsl:apply-templates select="/Figures"/>
</xsl:template>

<xsl:template name="Text">:method text: Text nodes in the template
  are directly send to the output stream.
<tag>XML-tags are not processed!</tag>
------------------------------------------------------------
</xsl:template>

<xsl:variable name="newLine">
<xsl:text>
</xsl:text>
</xsl:variable>

<xsl:variable name="tab">
<xsl:text>&#9;</xsl:text>
</xsl:variable>

<xsl:template match="Figures">
  <xsl:apply-templates select="Figure"/>
</xsl:template>

<xsl:template match="Figure">
  <xsl:text>Figure Id = </xsl:text>
  <xsl:value-of select="@Id"/>
  <xsl:value-of select="$tab"/>
  <xsl:text> Name = </xsl:text>
  <xsl:value-of select="Name"/>
  <xsl:value-of select="$tab"/>
  <xsl:text>Size = </xsl:text>
  <xsl:value-of select="Size"/>
  <xsl:value-of select="$newLine"/>
</xsl:template>

</xsl:stylesheet>
```

```
<xsl:output method="text" encoding="ISO-8859-1"/>
```

Diese Anweisung definiert eine von drei Ausgabe Methoden: text, xml oder html und die Codierung des erzeugten Files.

Die Vorlage

```
<xsl:template match="/">
  <xsl:call-template name="Text"></xsl:call-template>
  <xsl:apply-templates select="Figures"/>
</xsl:template>
```

bezieht sich auf die Wurzel des Dokuments und definiert, was zuerst passiert. Der Aufruf des Templates mit dem Namen "Text" produziert einige Ausgaben, ändert aber den Kontext nicht.

Die nächste Instruktion macht das Element `Figures` zum aktuellen Kontextknoten und ruft das zum Kontext passende Template auf. Im Template für `Figures` wird durch den XPath Ausdruck `Figure` eine Knotenliste mit allen `Figure` Elementen zum aktuellen Kontext und das Template zu `Figure` für alle Knoten dieser Liste ausgeführt.

Am Beginn des Style Sheets sind zwei globale "Variablen" definiert. Die Werte dieser Variablen sind die Steuerzeichen für einen Zeilenumbruch und den Tabulator.

```
<xsl:text>Figure Id = </xsl:text>
<xsl:value-of select="@Id"/>
<xsl:text>  Name = </xsl:text>
<xsl:value-of select="Name"/>
<xsl:value-of select="$newLine"/>
```

Diese Anweisungen schreiben den Text "Figure Id = " gefolgt vom Wert des Id-Attributes auf den Ausgabestrom. Beachte, dass der aktuelle Kontext ein Figure-Knoten ist, deshalb selektiert der XPath Ausdruck "@Id" das Id-Attribute des "Figure" Elements. Der Wert des selektieren Elements "Name" ist der Inhalt des Elements "Name". Anschließend wird noch eine neue Zeile erzeugt.

8.5.2 XML Dokument in ein HTML File transformieren

Drei Beispiele zeigen die Transformation eines XML Dokuments in ein HTML-File.

ToHtml1.xslt, ToHtml2.xslt und ToHtml3.xslt.

Quelltext des ersten Beispiels:

```
<?xml version="1.0"?>
<xsl:stylesheet version="1.0"
    xmlns:xsl="http://www.w3.org/1999/XSL/Transform">

<xsl:output method="html" encoding="ISO-8859-1"/>

<xsl:template match="/">
<html>
  <head>
    <title>Result of XSLT</title>
  </head>
  <body>
    <h3>Figure List</h3>
    <table border="1" cellspacing="0" cellpadding="3" width="60%">
      <tbody>
        <tr>
          <td><b>Id</b></td>
          <td><b>Name</b></td>
          <td><b>Size</b></td>
          <td><b>Area</b></td>
        </tr>
        <xsl:apply-templates select="/Figures/Figure"/>
      </tbody>
    </table>
  </body>
</html>
</xsl:template>
```

```
<xsl:template match="Figure">
  <tr>
    <td><xsl:value-of select="@Id"/></td>
    <td><xsl:value-of select="Name"/></td>
    <td><xsl:value-of select="Size"/></td>
    <xsl:variable name="s" select="Size"/>
    <xsl:choose >
      <xsl:when test="Type='Circle'">
        <td><xsl:value-of select="format-number($s*$s*3.1415 div
  4.0, '#.##')"/></td>
      </xsl:when>
      <xsl:when test="Type='Square'">
        <td><xsl:value-of select="format-number($s*$s,
  '#.##')"/></td>
      </xsl:when>
      <xsl:when test="Type='Triangle'">
        <td><xsl:value-of select="format-number(1.7321*Size*Size div
  4.0, '#.##')"/></td>
      </xsl:when>
      <xsl:otherwise>
        <td>---</td>
      </xsl:otherwise>
    </xsl:choose>
  </tr>
</xsl:template>

</xsl:stylesheet>
```

Wenn die Ausgabemethode `html` oder `xml` ist, werden alle Tags außer den `<xsl:…>` Tags einfach an den Ausgabestrom weitergereicht.

8.5.3 XML nach XML

Dies ist sehr ähnlich wie die Transformation nach HTML. Transformationen von XML nach XML erlauben eine praktisch beliebige Umwandlung eines Quelldokuments in ein neues Dokument. Man kann diese Technik z.B. zum Sortieren von Listen oder zum laden und schreiben von XML-Dokumenten in verschiedenen Versionen verwenden.

Das folgende Beispiel liest wieder eine Liste von Figuren und transformiert das File in ein File, dass für jedes Figure Element den Namen löscht und ein ColorNr Element einfügt.

```
<?xml version="1.0" encoding="UTF-8"?>
<xsl:stylesheet version="1.0"
  xmlns:xsl="http://www.w3.org/1999/XSL/Transform">
  <xsl:output method="xml" version="1.0" encoding="UTF-8"
  indent="yes"/>

<xsl:template match="/">
  <Figures>
  <xsl:apply-templates select="/Figures/Figure"/>
  </Figures>
</xsl:template>

<xsl:template match="Figure">
  <Figure>
    <xsl:copy-of select="Type" />
    <xsl:copy-of select="Size" />
    <ColorNr>0</ColorNr>
  </Figure>
</xsl:template>

</xsl:stylesheet>
```

8.5.4 XSLT im Programm

Aus der Dokumentation zu Visual Studio:

The goal of the Extensible Stylesheet Language Transformation (XSLT) is to transform the content of a source XML document into another document that is different in format or structure. For example, to transform XML into HTML for use on a Web site or to transform it into a document that contains only the fields required by an application. This transformation process is specified by the W3C XSL Transformations (XSLT) Version 1.0 recommendation located at www.w3.org/TR/xslt. In the .NET Framework, the `XslTransform` class, found in the `System.Xml.Xsl` namespace, is the XSLT processor that implements the functionality of this specification. There are a small number of features that have not been implemented from the W3C XSLT Version 1.0 recommendation, listed in Outputs from an `XslTransform`. The following figure shows the transformation architecture of the .NET Framework.

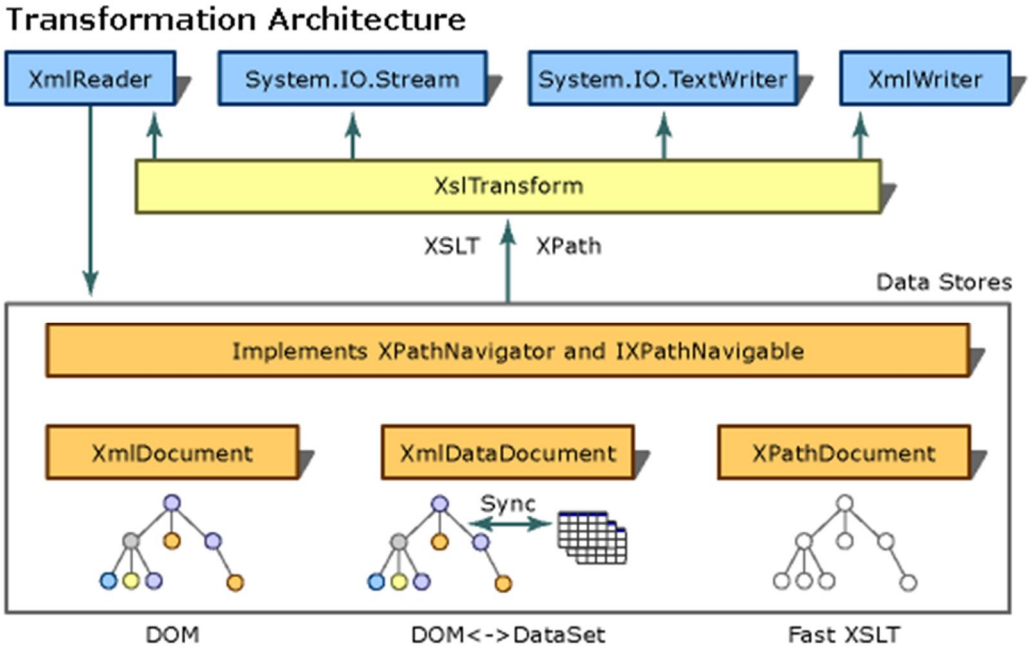

The XSLT recommendation uses XPath to select parts of an XML document, where XPath is a query language used to navigate nodes of a document tree. As shown in the diagram, the .NET Framework implementation of XPath is used to select parts of XML stored in several classes, such as an `XmlDocument`, an `XmlDataDocument`, and an `XPathDocument`. An `XPathDocument` is an optimized XSLT data store, and when used with `XslTransform`, it provides XSLT transformations with good performance.

Beispiel:

```
using System;
using System.IO;
using System.Xml;
using System.Xml.XPath;
using System.Xml.Xsl;

public class Sample
{
    private const String filename = "mydata.xml";
    private const String stylesheet = "myStyleSheet.xsl";

    public static void Main()
    {
      XslTransform xslt = new XslTransform();
      xslt.Load(stylesheet);
      XPathDocument xpathdocument = new
      XPathDocument(filename);
      XmlTextWriter writer = new XmlTextWriter(Console.Out);
      writer.Formatting=Formatting.Indented;

      xslt.Transform(xpathdocument, null, writer, null);
    }
}
```