εχTEX

Projektvorstellung, Möglichkeiten, Ideen, ...

Michael Niedermair m.g.n@gmx.de

TEX-Stammtisch München, April 2004

1 Projektvorstellung

1.1 Wie alles begann

- Dezember 2002: Rolf Niepraschk und Markus Kohm suchen nach Möglichkeiten, Java in C++ umzuwandeln (konkret NTS). Einstieg von Michael Niedermair.
- Einarbeitung in den NTS-Code und Tests, ob dieser mit GCJ (GNU-Compiler für Java) in Nativecode umgewandelt werden kann und dadurch schneller wird.
- Januar 2003: Umstellung des NTS-Code und Einbau von Erweiterungen (z. B. Funktionen von εTEX, neue und erweiterte Register, ...)

- Sommer 2003: Da der Umbau des NTS-Codes sich als sehr aufwändig herausstellte, wurde beschlossen, ein komplett neues System auf Basis der Erfahrungen von NTS, εTEX, pdfTEX und Ω (Omega) zu entwickeln – εχTEX.
- Oktober 2003: Klausurtagung in Heidelberg, um Ideen und Möglichkeiten zu sammeln.

1.2 Wer sind wir?

Inzwischen ist der Kreis der εχTEX-Interessierten stark angewachsen. Diese teilen sich auf in

- aktive Programmierer,
- Tester,
- Dokumentationsersteller,
- Berater und
- Interessierte.

Auf der Mailingliste finden sich:[a]

Torsten Bronger
Christian Faulhammer
Patrick Gundlach
David Kastrup
Markus Kohm
Alexander Kraenzlein
Torsten Krueger
Gerd Neugebauer
Michael Niedermair
Rolf Niepraschk
Heiko Oberdiek
Bernd Raichle
Walter Schmidt

[a] in alphabetischer Reihenfolge

1.3 Konzept

❣ Bitte überlegen, wo man evtl. Mithelfen kann! ❣

- Aufteilung in möglichst unabhängige Hauptmodule, die beliebig ausgetauscht werden können
- Beliebige Konfiguration über Konfigurationsdatei und Aufrufparameter,
  zum Beispiel Auswahl des Typesetters oder des Silbentrennungsalgorithmus

- εχTEX wird alle Primitiven von TEX und alle satztechnischen Primitiven von εTEX enthalten.
- εTEX-Primitiven, die zur Fehlersuche dienen, werden durch umfangreiche Debugmöglichkeiten von εχTEX ersetzt.
- Rechts-Links-Primitiven werden durch die Möglichkeiten von Ω realisiert.

- Zusätzlich weitere Primitiven, die die Funktionen erweitern bzw. ausbauen
- entsprechende Formatdateien, so dass εχTEX Tests von εTEX oder pdfTEX besteht
- Ziel: εχTEX soll in der Lage sein, real existierende Dokumente augenscheinlich identisch zu umbrechen
- und irgendwann Umsetzung von vielen Ideen, ...

  später mehr dazu

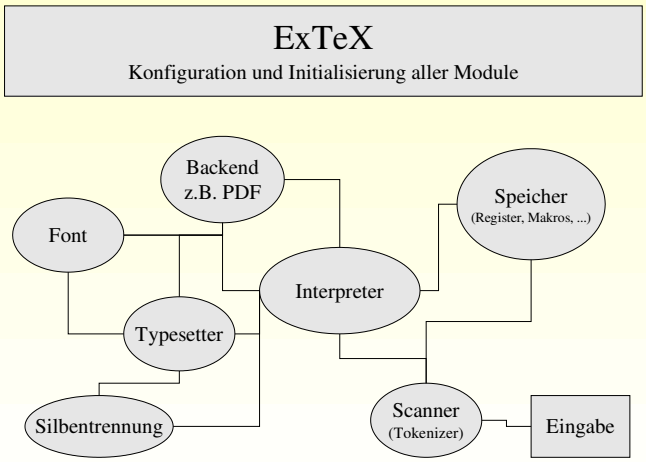

2 Module

2.1 ExTeX: Hauptbereich

- Einlesen und Auswerten der Konfigurationsdatei (XML-Format)

```
...
<define name="count" class="de.dante.extex.interpreter.primitives.register.
     NumberedCount"/>
<define name="countdef" class="de.dante.extex.interpreter.primitives.register.
     CountDef"/>
...
<Typesetter class="de.dante.extex.typesetter.impl.TypesetterImpl">
   <LineBreaker name="default" class="de.dante.extex.typesetter.impl.
        LineBreakerImpl"/>
   <LineBreaker name="XXX" class="de.dante.extex.typesetter.impl.
        LineBreakerXXXImpl"/>
</Typesetter>
```


- Definition aller Primitiven
- Auswerten der Aufrufparameter
- Initialisierung der gesamten Module
- Start des Interpreters

2.2 Scanner

- Einlesen der Zeichen aus einer Datei und Umwandlung in Tokens
- Intern werden die Zeichen im 32-Bit-Format (UTF-32) gespeichert.
- Steuerung über

```
\inputencoding{ISO8859-1}
```

und

```
\inputfileencoding{ISO8859-1}{testnew}
```

- bzw. über Unicodename

```
^^^LATIN CAPITAL LETTER A WITH DIAERESIS;
```

- Für das Encoding werden die Standardencoder von Java verwendet, die sich auch beliebig erweitern lassen.

  Big5, Big5-HKSCS, EUC-JP, EUC-KR, GB18030, GBK, ISO-2022-JP, ISO-2022-KR, ISO-8859-1, ISO-8859-13, ISO-8859-15, ISO-8859-2, ISO-8859-3, ISO-8859-4, ISO-8859-5, ISO-8859-6, ISO-8859-7, ISO-8859-8, ISO-8859-9, JIS_X0201, JIS_X0212-1990, KOI8-R, Shift_JIS, TIS-620, US-ASCII, UTF-16, UTF-16BE, UTF-16LE, UTF-8, windows-1250, windows-1251, windows-1252, windows-1253, windows-1254, windows-1255, windows-1256, windows-1257, windows-1258, windows-31j, x-EUC-CN, x-euc-jp-linux, x-EUC-TW, x-ISCII91, x-JIS0208, x-Johab, x-MS950-HKSCS, x-mswin-936, x-windows-949, x-windows-950

2.3 Interpreter

- Token: Ausführen, Expandieren bzw. dem Typesetter übergeben.
- ...

2.4 Speicher

- Speichern von Registern, Makros, ...
- ...

2.5 Typesetter

- Bilden von vertical und horizontal lists
- Zeilenumbruch, Silbentrennung, Absatzumbruch
- Möglichkeit des Umschaltens des Zeilenumbruch- bzw. Absatzumbruchmechanismus (für jeden Absatz)
- Einlesen der Maße für die entsprechenden Glyphen (Höhe, Tiefe, Breite, Kerning, ...)
- Ligaturen
- ...

2.6 Font

- Einlesen der Fontmetriken aus
  - TFM (TeX Font Metrik)
  - AFM (Adobe Font Metrik)
  - TTF (TrueType Font)
  - OTF (OpenType Font) in Arbeit
  - OFM (Omega Font Metrik) in Planung
  - ...
- Bilden von Metrik-, Ligatur- und Kerning-Tabellen, etc. für eine allgemeine interne Darstellung

Ideen

- Optischer Randausgleich: für jeden Glyphen wird angegeben, wieviel rechts und links weggenommen werden kann.
- Kerningdaten in Gruppen (siehe OTF)
- SVG-Fonts
- ...

2.7 Backend

- Erzeugen des Output-Formates
- Vorerst drei Formate:
  - PDF
  - Text (erstmal nur für den schnellen Test)
  - Dump (für Debug-Zwecke: hier werden alle Nodes mit Ihren Daten in eine ASCII-Datei geschrieben)

3 Stand der Entwicklung

in Arbeit „fast“ fertig

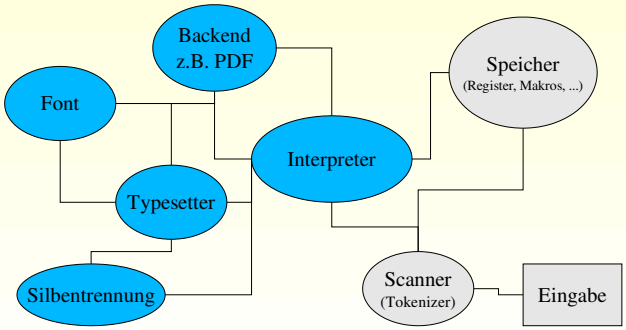

4 Was ist geplant?

- εTEX Funktionen (ohne Umschalten der Schreibrichtung; dieses kann mit Ω-kompatiblen Primitiven auf Makroebene nachgebildet werden)
- Ω (Omega) Funktionen: Möglichkeiten der Beeinflussung der Schreibrichtung

- pdfTEX Funktionen bezüglich typografischen Fähigkeiten (z.B. optischer Randausgleich).
  Primitiven bzgl. Verarbeitung von Bildern (jedoch ohne das Präfix „`pdf`“) mit neuen Treibern für *graphics* bzw. *hyperref*.
  Unterstützung von zusätzlichen Bildformaten.
- Grafische Elemente wie Linien beliebiger Steigung, Ellipsen, Bezier-Kurven usw.
  Ebenso sollen grafische Transformationen wie Rotation, Spiegelung, Skalierung realisiert werden.

- Einbinden von „anderen“ Eingabeformaten
  - XML (für Daten und Text)
  - XML-FO
  - OpenOffice-Dokumente
  - ...
- weitere Backends
  - SVG
  - ...

4.1 Ungelöstes

- Satz von Absätzen, die von der üblichen rechteckigen Form (Höhe, Tiefe, Breite) abweichen.
  Idealerweise an jeder beschreibbaren Figur.
- Schriftenmanagement
  - Mikrojustierung der Buchstabenabstände und -größen
  - Randausgleich (andere, evtl. bessere Methoden)
  - Laufweitenausgleich u. ä. (z.B. durch Spacing, Größenänderung, ...)

- Die Möglichkeit der Optimierung der Absatz- und Seitenumbrüche über mehrere Seiten hinweg.
- Registerhaltigkeit der auf der Seite angeordneten Boxen.
- ...

5 Grafik

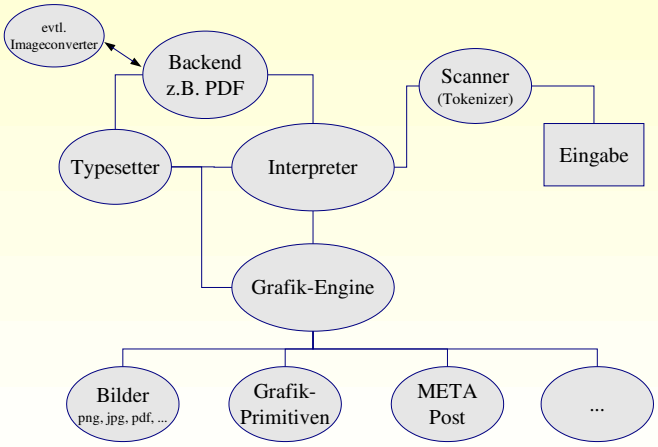

5.1 Aufgabe

- Einbinden von Bildern
  verschiedene Formate: png, jpg, pdf, ...
  Welche Formate sind noch sinnvoll?
- Zeichnen mit Grafik-Primitiven
  line, frame, circle, ...
  Welche werden benötigt?
  Wie werden Parameter übergeben?

- Zeichnen mit METAPost
  Erweiterungen notwendig?
- ...

5.2 Probleme

- Text im Bild
  Grafikengine übergibt Text in einer Box an den Typesetter und dieser bricht diesen um?
  Alternative Möglichkeiten?
- Was macht man, wenn der Backend das Grafikformat nicht versteht?
  Imageconverter?
- ...

6 Aufruf

- In einigen Bereichen fehlt uns schlicht noch das notwendige Fachwissen. Wer hilft?
- Was haben wir vergessen?
- Wer hat Wünsche?
- Wer hilft bei der Implementierung und beim Ausprobieren neuer Methoden?

Fragen?