



Schnupperstudiums-Projekt

„Mensch-Maschine-Kommunikation mit  
gesprochener Sprache

## Einführung in VoiceXML

Cristina Vertan

[vertan@informatik.uni-hamburg.de](mailto:vertan@informatik.uni-hamburg.de)

## Was lernen wir hier?

- Wie funktioniert VoiceXML?
- Grundelemente in VoiceXML
- Aufbau eines modularen Programmes (Subdialoge)

z.B.: Ein Benutzer, der einen ausgebuchten Kinofilm sehen möchte, gelangt nicht mehr zur Buchung. Er wird aufgefordert, einen anderen Film zu buchen o.ä.

- Wie gebe ich dem Benutzer eine bestimmte Freiheit in seiner Aussage? (Grammatiken)

z.B.: "Wohin möchten Sie fliegen?"

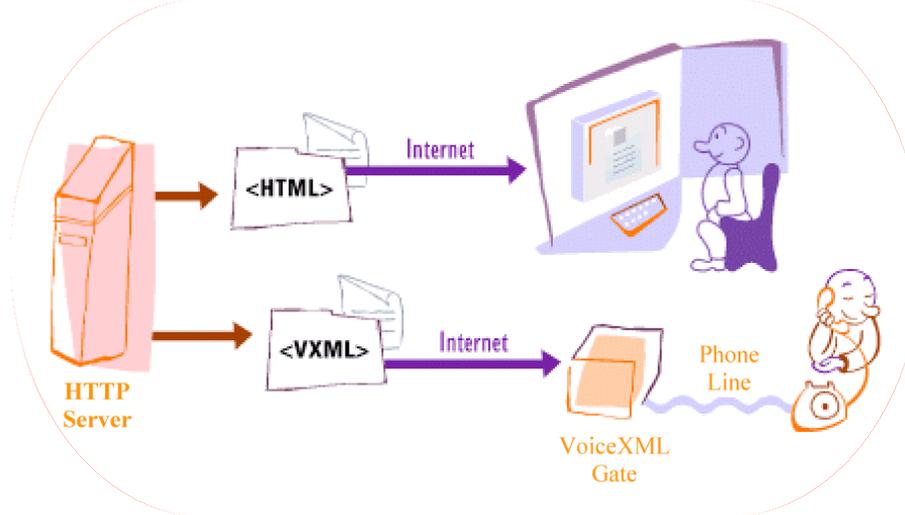
Prag

Ich möchte nach Prag.

Ich möchte nach Prag fliegen.

# Was ist Voice-XML?

- Voice-XML
  - Ist eine XML-basierte Dialog-Markup-Sprache
  - Sie verbindet WWW mit Telefon und Wireless-Geräten



- Wird (normalerweise) von einem Voice-Browser statt einem GUI-Browser, z.B. Explorer, ausgeführt
- Voice-XML-Anwendungen ermöglichen:
  - Benutzereingabe durch Sprachsignale oder Telefontasten
  - Sprachausgabe durch Sprachsynthese oder Audiodateien

# Voice-XML: ein einfaches Beispiel

**C:** Wählen Sie bitte eines der folgenden Themen: Sport, Wetter, Nachrichten

**B:** Wechselkurse

**C:** Ich habe Sie leider nicht verstanden (*Default-Antwort*)

**C:** Wählen Sie bitte eines der folgenden Themen: Sport, wetter, Nachrichten

**B:** Sport

**C:** *führt den Dialog, der in sport.vxml beschrieben ist, durch*

```
<?xml version=„1.0“?>
<!DOCTYPE ...>
<vxml version=„2.0“ xmlns=„...“>
<menu>
  <prompt> Wählen Sie bitte eines der
    folgenden
    Themen:<enumerate/></prompt>
  <choice next=„http://...“>Sport</choice>
  <choice
    next=„http://...“>Wetter</choice>
  <choice
    next=„http://...“>Nachrichten</choic
    e>
  <noinput> Wählen Sie bitte eines der
    folgenden Themen:<enumerate/>
</menu>
</vxml>
```

## Analogie mit GUI

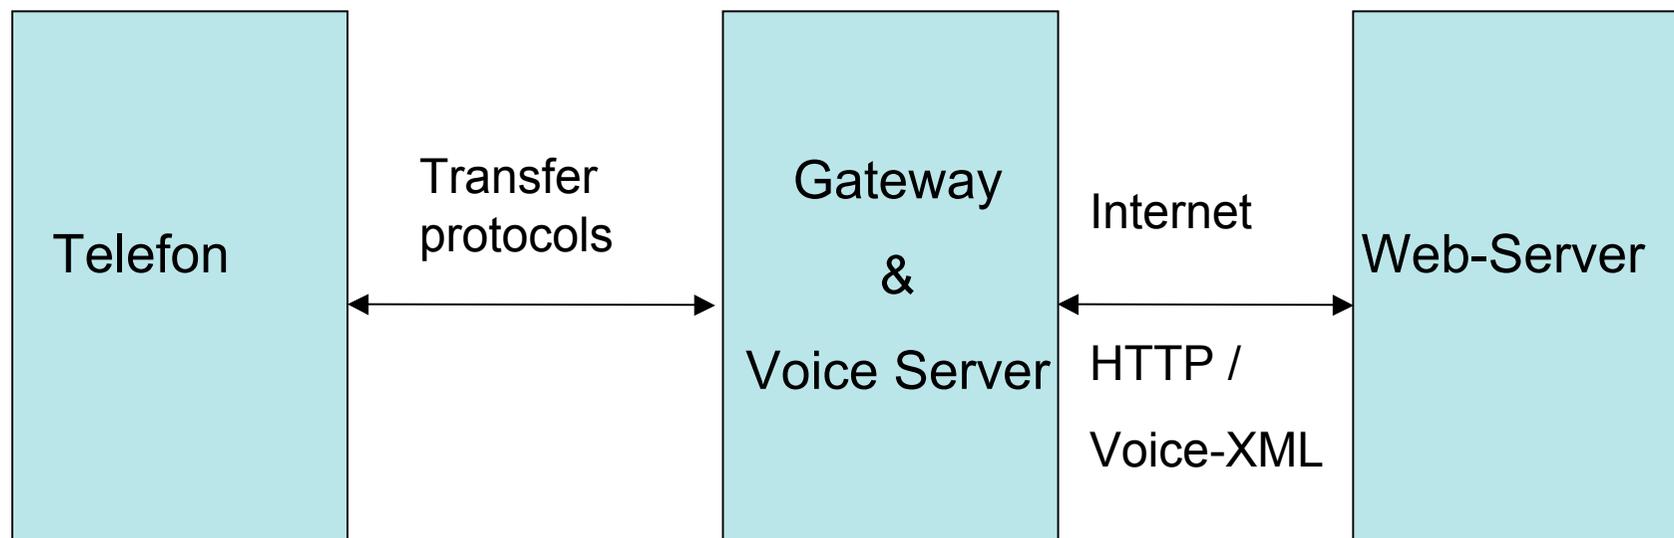
Wählen Sie bitte einer der folgenden Themen.  Sport

Wetter

Nachrichten

- Vorteile GUI: Die Eingabe des Benutzers wird eindeutig vom System erkannt
- Nachteile GUI:
  - Flexiblere Eingaben, wie „Sagen Sie mir etwas über Sport“, sind nicht möglich
  - Man ist abhängig von der Existenz eines Bildschirms

# Wie arbeitet VoiceXML?



Telefon  
Handy

Telefonschnittstelle  
Voice-Browser  
Spracherkenner  
Sprachsytheser  
Touchtone  
Audioplay record

VoiceXML-Dokumente  
Audio-Dateien  
DB-Schnittstelle  
Transaktionsbearbeitung

## Was muss ich kennen um einen einfaches Dialogsystem aufzubauen?

- Spracherkenner und Sprachsyntheser sind vorhanden. Kostenlose Versionen sind nicht extrem performant, aber reichen für unser Projekt aus.
- Der VoiceXML-Interpreter ist vorhanden
- DTD-Spezifikation und alles was, mit XML/VXML-Versionen zu tun hat, kann man aus der Muster-Datei kopieren.
- **Minimale Kenntnisse über Markup-Syntax**
- **Grund-Elemente aus der VoiceXML-Syntax**

## Auf was muss ich bei der Syntax achten?

- Ein Tag wird durch die „<“ bzw. „>“-Klammer spezifiziert.
- Die Tags kann man nicht beliebig erweitern. Auf der VoiceXML-Einführungs-Webseite findet ihr alle vorhandenen Tags
- Die meisten Tags sind paarweise vorhanden:
  - <tag> ein öffnender Tag
  - </tag> ein schliessender Tag
  - dazwischen steht die für diesen Tag wichtige Information
- Falls ein Tag keine Information enthält, schreibt man
  - <tag/>
- Ein Tag kann Attribute, also Beschreibungen, enthalten, dann sieht es so aus:
  - <tag Attribut1=„wert1“ Attribut2=„wert2“ ...>
  - Meistens sind Attribute optional, müssen also nicht zwingend angegeben sein
  - welche Attribute für welchen Tag möglich sind, ist festgelegt

# VoiceXML Elemente /Tags

- `<vxml>` erstes Element in jedem VXML-Dokument
- `<form>` leitet einen Dialog (zur Informationsdarstellung oder Datensammlung) ein
- `<block>` enthält nicht-interaktiven (=executable) Code
- `<prompt>` markiert Audio-Ausgaben (synthetisiert oder aus Datei)
- `<field>` markiert ein Eingabefeld in einem `<form>`
- `<filled>` nennt in einem Feld die Aktion, die nach Füllen des einbettenden Feldes startet
- `<menu>` ein in `<form>` eingebetteter Dialog zur Auswahl aus Alternativen
- `<choice>` definiert je ein Menu-Item
- `<grammar>` spezifiziert die gültige Grammatik
- `<goto>` Verbindung zu einem anderen Dialog in demselben oder einem anderen Dokument

# Beispiel

Versionsangaben zu VXML

Kommentar

block erwartet keine Aktion -  
hier ist die Begrüßung damit realisiert

enumerate bewirkt, dass die  
nachfolgenden choices aufgezählt werden

field wird über den Namen angesprochen

```
<?xml version="1.0" encoding="ISO-8859-1" ?>
<vxml xmlns="http://www.w3org/2001/vxml"
version="2.0">
  <!--Hello World Program -->
  <form>
    <block>
      <prompt> Guten Tag!
    </prompt>
    </block>
    <field name="abteilung">
      <prompt>Mit welcher Abteilung darf ich Sie
        verbinden?<enumerate/>
      </prompt>
      <choice next="abtA">Abteilung A</choice>
      <choice next="abtB" >Abteilung B</choice>
      <prompt>Ich verbinde Sie mit <value expr="abteilung"/>.
        Auf Wiederhören.
      </prompt>
    </field>
  </form>
</vxml>
```

# Dialogentwurf-Prinzipien -1-

- Das Kurzzeitgedächtnis soll nicht überfordert werden.
- Deswegen:
  - darf man nicht mehr als 7 Auswahlmöglichkeiten benutzen (optimal 3 oder 4)
  - für jeden Schritt muss eine entsprechende Anweisung definiert werden
  - Die Benutzer sollen den nächsten Schritt überschauen können
  - Globale Information soll nicht benutzt werden, weil sie nicht erinnert werden kann
- Für multimodale Systeme sind diese Prinzipien nicht so streng.
- Trotzdem muss man immer daran denken, dass die Kommunikationszeit so kurz wie möglich sein soll, und dass die Bildschirm-Möglichkeiten begrenzt sind.

## Dialogentwurf-Prinzipien -2-

- Dialogverhalten ist nicht immer fehlerlos. Deswegen
  - muss der Benutzer wissen, was er sagen darf,
  - sollen die Prompts eine vernünftige Zahl von Auswahlmöglichkeiten geben
  - Für Dialogabweichungen müssen Event-Handler geschrieben werden (d.h. was passiert, wenn der Benutzer etwas sagt, was das System nicht bearbeiten kann)
- Außerdem muss man immer daran denken, dass der Benutzer häufig versucht, mit dem System zu reden wie mit einer Person.

# VoiceXML-Dialoge -1-

- Es gibt 2 Typen von Dialogelementen:
  - form
  - menu
- Forms sammeln Werte (Sätze/Wörter/Tasteneingaben), die eine Variable (Feld) binden sollen (sie sind ähnlich wie Textfelder in GUIs)
- Event-Handler müssen für solche Werte (Sätze/Wörter/ Tasten) geschrieben werden, die im Sinne der Grammatik nicht gültig sind,
- Aktionen werden durchgeführt, wenn die nötigen Variablen (Felder) nach der Filled-Bedingung spezifiziert sind

## VoiceXML-Dialoge -2-

- Menüs geben dem Benutzer eine Auswahlmöglichkeit
- Die Dialog-Transition (Umschaltung in einen anderen Dialog) ist auf eine Auswahl beschränkt
- menu ist eine “Abkürzung” für eine Form mit nur einem Feld
- Menüs sind für Sprachanwendungen noch einfacher zu beherrschen, andererseits muss man bedenken, dass sie den Benutzer relativ stark einschränken.

## Dialog-Transitionen

- Werden via URI (Uniform Resource Identifier) spezifiziert,
- Ein URI definiert den nächsten Dialog im aktuellen oder einem anderen Dokument,
- Spezifiziert ein URI kein Dokument, gilt das aktuelle Dokument als “default”
- Spezifiziert ein URI keinen Dialog, gilt der erste Dialog als “default”
- Transitionen werden angegeben mit den Tags:
  - <choice next=URI>
  - <goto next URI>
  - <link next URI>

# Menu Template

`<enumerate/>`  
bewirkt eine  
Wiederholung der Frage  
und der Auswahl

```
<menu id=Identifizier>  
  <prompt> Question <enumerate/> <prompt>  
  <choice next=URI-1> Phrase-1 </choice>  
  <choice next=URI-2> Phrase-2 </choice>  
  <choice next=URI-3> Phrase-3 </choice>  
  <noinput> Message <enumerate/></noinput>  
</menu>
```

## Catch und Help Element

Das <help> -Element ist eine Abkürzung für

```
<catch event="help"> ....</catch>
```

z.B.

```
<help>
```

Please say Student Accommodation, Courses or  
Sport

```
</help>
```

# Implizite Verifizierung den Benutzereingaben

```
<form id=„courses_details“>  
<block>Welcome to Courses Details</block>  
<field name=„course_type“>  
  <prompt> Please specify the type of course </prompt>  
  <grammar> Proseminar | Seminar | Project | Praktika </grammar>  
</field>  
<field name=„confirm“ type „boolean“>  
<prompt> List courses of type <value expr=„course_type“/> </prompt>  
<filled>  
<if cond=“confirm“>  
<prompt> You can register to following <value expr=„course_type“/> </prompt>  
<else /> try once more  
<clear namelist=„course_type confirm“/>  
</if> </filled></field></form>
```

Implizite Antwort  
„yes/no“ and  
variants

Löscht die Werte von  
Feldern *course\_type* and  
*confirm*

*Variables set to undefined*

# Subdialog

- Ein Subdialog ist eine neue Interaktion, die innerhalb eines Dialoges erzeugt wurde
- Alle Werte der Variablen und der aktivierten Grammatiken werden gespeichert. Für den neuen Subdialog ist damit eine neue Umgebung initialisiert.
- Wenn der Subdialog beendet ist, wird der Hauptdialog dort fortgesetzt, wo er unterbrochen wurde. Die Variablen und Grammatiken des Hauptdialoges sind wieder aktiv.
- Ein Subdialog wird durch `<subdialog>` initialisiert.
- Die Rückkehr zum Hauptdialog ist mit `<return>` markiert

## VoiceXML -Beispiel für Subdialoge

```
<?xml version=„1.0“>
<vxml version=„2.0“>
<menu id=„mainmenu“>
  <prompt> Welcome to the Student System Main Menu. The
    system provides you with information about student
    accommodation, courses and administrative issues. To begin
    say one of the following:
  </prompt>
  <enumerate/>
  <choice next=„accommodation.vxml“> accommodation </choice>
  <choice next=„courses.vxml“> courses </choice>
  <choice next=„administration.vxml“> administration </choice>
</menu>
</vxml>
```

# Variablentransfer von einem **Subdialog** in einen **Hauptdialog**

```
<block> Welcome to the Student Information System </block>  
<subdialog name=„result“ src=„#validation“> </subdialog>  
<block>  
<prompt>  
Hello <value expr=result.username“ />  
</prompt>  
</block></form>
```

```
<!-- subdialog -->  
<form id=„validation“>  
<field name=„username“>  
<grammar> Schröder | Schmidt | Schulz | Guest </grammar>  
<prompt> Please say your username </prompt>  
</field>  
<filled><return namelist=„username“ /> </filled>  
</form>
```

# Variablentransfer von einem Hauptdialog zu einem Subdialog

```
<form id=„main_menu“>
<block> Welcome to the Student Information System </block>
<field name=„username“>
<grammar> Schröder | Schmidt | Schulz | guest </grammar>
<prompt> Please say your user name </prompt>
</field>
<subdialog name=„result“ src=„#validation“>
<grammar name=„name“ expr=„username“/>
</subdialog>
</form>
```

```
<!-- subdialog -->
<form id=„validation“>
<var name=„name“/>
<block>
<prompt> hello <value expr=„name“/></prompt> <return />
</block></form>
```

# Was ist eine Dialoggrammatik?

- Eine Dialoggrammatik enthält eine Regelmenge, die eine
- Sammlung von Wörtern und Sätzen spezifiziert, die von dem Spracherkenner erkennbar sind
- Es gibt verschiedene Formalismen, um eine
- Dialoggrammatik zu spezifizieren, wie:
  - Nuance Grammar Specification Language (GSL)
  - Speech Recognition Grammar Specification (SRGS)
  - usw.

## Einbettung einer Grammatik - inline

```
<?xml version="1.0"?>
<vxml version="2.0">
<form id="start">
  <field name="Schaden">
    <prompt> Wo haben sie ein Problem?</prompt>
    <grammar type="application/x-gsl">
      ?(Mein Problem ist am) [Motor Fahrwerk Vergaser]
    </grammar>
  <filled>
    <prompt> Ich habe verstanden : sie haben ein
      Problem am <value expr="Schaden"/>
    </prompt>
  </filled></field></form></vxml>
```

# GSL-Syntax

- $[A B C \dots Z]$  bedeutet A oder B oder C oder ... oder Z
- $(A B C \dots Z)$  bedeutet A und B und C und... und Z
- $?A$  bedeutet A ist optional
- $+A$  bedeutet eine oder mehrere Wiederholungen von A
- $*A$  bedeutet keine oder mehrere Wiederholungen von A

## GSL Grammatik: Beispiel für Synonyme

<prompt> Welche Farbe hat ihr Wagen ? </prompt>

<grammar type=application/x-gsl">

<![CDATA[

?(Meine Wagen hat eine)

[ blaue {<colour "blau">}

türkise {<colour "blau">}

grüne {<colour "grün">}

.....]

?(Farbe) ]]>

</grammar>

<filled>

<prompt> Also: Ihr Auto ist <value expr="colour"/></prompt>

</filled>

# Trennung von Grammatik und VoiceXML-Datei

- Man schreibt die Grammatik in eine Datei (.gsl)
- Entsprechend des gewählten Formalismus,
- Im Dialogskript steht dann:

```
<grammar src="colour.gsl#Farbe" type="application/x-gsl"/>
```



```
Farbe  
(?(Mein Wagen hat eine)  
[ blaue {<colour "blau">}  
türkise{<colour "blau">}  
grüne {<colour "grün">}  
.....]  
?(Farbe) )
```

**Viel Spaß bei der Anwendung !**