Human-Computer Interaction

Termin 11:
Natural Interaction - Multimodal Interfaces

The evolution of user interfaces

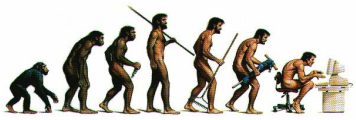

Year	Paradigm	Implementation
1950s	None	Switches, punched cards
1970s	Typewriter	Command-line interface
1980s	Desktop	Graphical UI (GUI), direct manipulation
1980s+	Spoken Natural Language	Speech recognition/synthesis, Natural language processing, dialogue systems
1990s+	Natural interaction	Perceptual, multimodal, interactive, conversational, tangible, adaptive
2000s+	Social interaction	Agent-based, anthropomorphic,social, emotional, affective, collaborative

Natural interfaces

- Highly interactive, multimodal interfaces modeled after natural human-to-human interaction

not just mouse, keyboard, monitor...

- *Goal*: For people to be able to interact with computers in a fashion similar to how they interact with each other and with the physical world

Natural human interaction

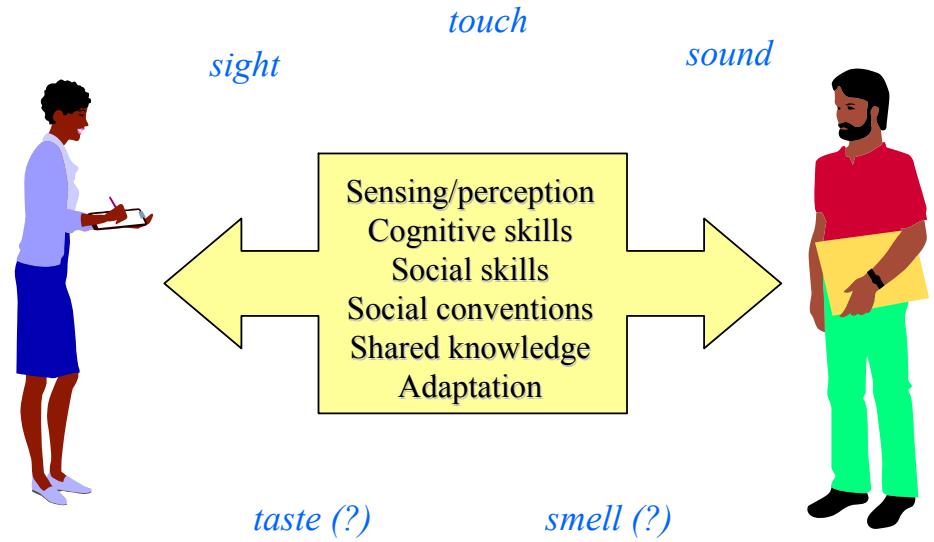

Natural interfaces

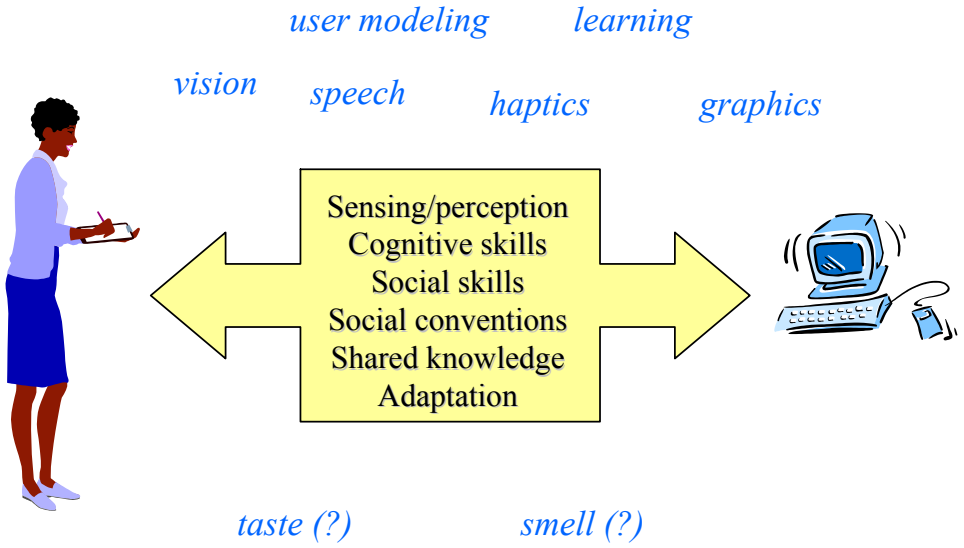

Modalität

Der Begriff „Modalität" wird unterschiedlich verwendet:

physiologisch

sensorische Modalität

Möglichkeiten der menschlichen Wahrnehmung:
visuell, auditiv, taktil, olfaktorisch, gustatorisch, vestibular

motorische Modalität

Möglichkeiten des Handelns bzw. Kommunizierens:
verbal, manuell, mimisch, körperlich

technisch

Modalität als *Interaktionstechnik*

Zusammenschluß <*d*,*L*> eines Interaktionsgeräts *d* mit einer Interaktionssprache *L*

Modalität & multimodal

Im folgenden verwendete Definition:

*Eine **Modalität** bezeichnet ein kommunikatives System, das durch die Art und Weise wie Information kodiert und interpretiert wird, gekennzeichnet ist.*

- Modalitäten betreffen sowohl die Informationsübertragung vom Menschen zur Maschine (technisch: Eingabemodalität) als auch von der Maschine zum Menschen (technisch: Ausgabemodalität)
- Eine Schnittstelle ist **multimodal**, wenn sie mehrere Eingabe-modalitäten und/oder Ausgabemodalitäten zur Verfügung stellt.

Natürliche Modalität & Kulturtechnik

- *Natürlich* oder *fundamental* ist eine Modalität, wenn sie Teil der kommunikativen Grundkompetenz eines (sozialisierten) Menschen ist – dazu gehören: *Sprache (Laute), Gestik, Mimik, Körpersprache (Proxemik)*
- Achtung: natürliche Modalitäten sind kulturabhängig! Ausnahme: Emotionen, die durch Mimik, Prosodie, Körpersprache ausgedrückt werden
- Neben den natürlich vorhandenen können Modalitäten erlernt werden: Kulturtechniken wie z.B. Lesen & Schreiben oder auch *point-and-click* als "Subkulturtechnik"

Warum multimodal?

Natürlichkeit & Intuitivität

- stärkere Anpassung an den Menschen
- interagieren geschieht automatisch/unbewusst
- Unterschiedliche Nutzer bevorzugen verschiedene Modalitäten, bessere Akzeptanz v.a. unter ungeübten Benutzern

Bandbreite & Effizienz der Informationscodierung

- Mehr Information pro Zeit ikommunizierbar

Adäquatheit der Informationscodierung/Multifunktionalität

- Informationsarten/Funktionen lassen sich mit verschiedenen Modalitäten verschieden gut übermitteln/erfüllen
  - propositional (Inhalt) vs. interaktionssteuernd (Turn-taking, Feedback, Aufmerksamkeit)
  - symbolisch vs. ikonisch vs. indexikalisch

Alternative Kommunikationswege *(universal design)*

- Berücksichtigung aller Benutzergruppen (z.B. Blinde) in allen Situationen (z.B. bei Umgebungslärm)

In Wirklichkeit multimodal und noch komplexer (Nicken, An-/Wegschauen, Handgesten, etc.)

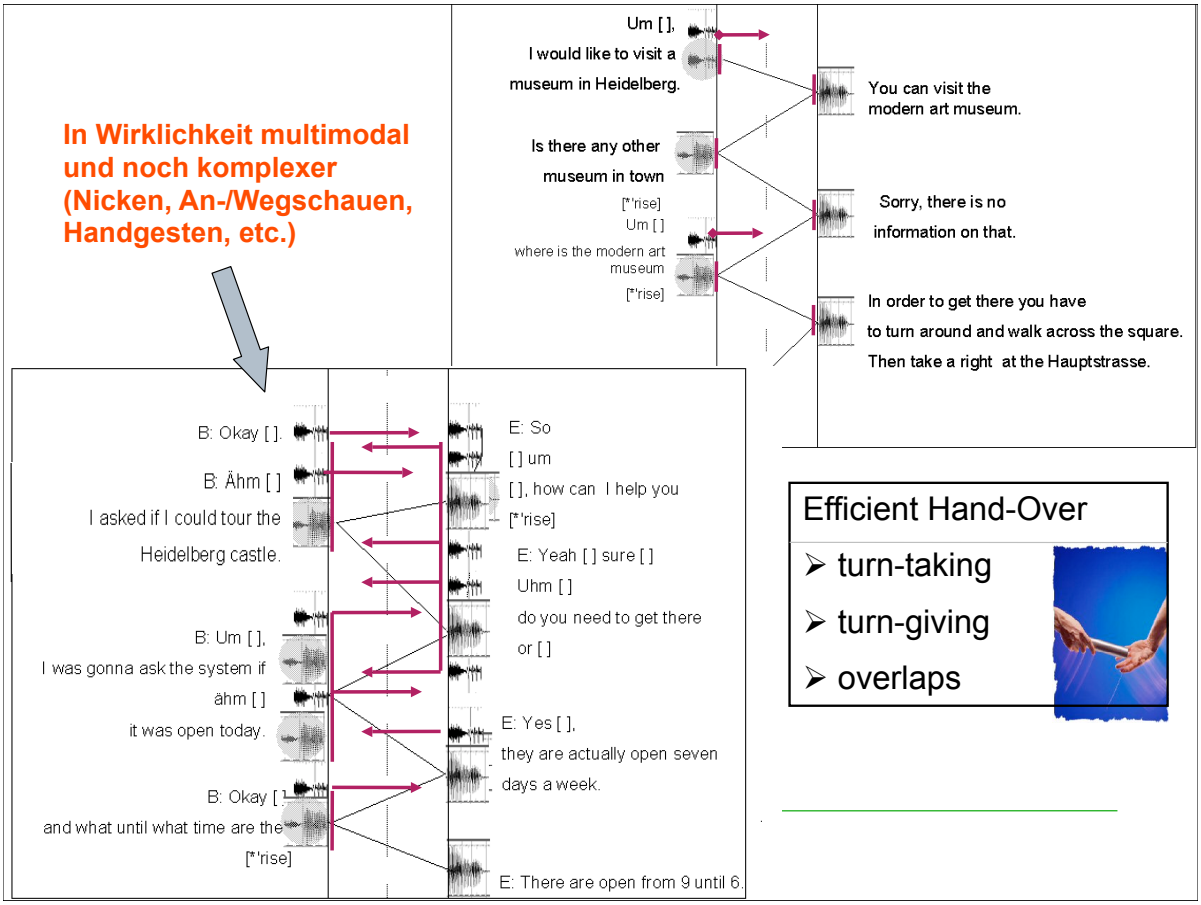

Efficient Hand-Over

- turn-taking
- turn-giving
- overlaps

Vorteile aus Systemsicht

Robustheit
- Weniger Überanspruchung und Abnutzung einer Modalität

Adaptivität
- Nutzbarkeit der besten Modalität unter wechselnden Bedingungen

Redundanz
- Übermittlung derselben Information über verschiedene Modalitäten kann die Fehlerrate verringern
- Gegenseitige Disambiguierung der Modalitäten

Fehleranfälligkeit/-behandlung
- Nutzer wählen intuitv weniger fehleranfälligen Modus, wechseln oft die Modalität nach Fehlerfall
- Nutzer verwenden simplere Sprache wenn sie multimodal interagieren – reduzierte Komplexität durch Aufteilung der Information

Einwände

- HCI should be characterized by (e.g. Shneiderman):
  - Direct manipulation
  - Predictable interactions
  - Giving responsibility and sense of accomplishment to users
- Won't work –"AI hard"
- Technologische Hürde (die einfachere)
  - Lots of researchers worldwide
  - Increasing interest
  - Consistent progress
- Ökonomische Hürde (die höhere)
  - But there's growing convergence: hw/sw advances, commercial interest in biometrics, accessibility, recognition technologies, virtual reality, entertainment....

Multimodale Systeme: Prinzip

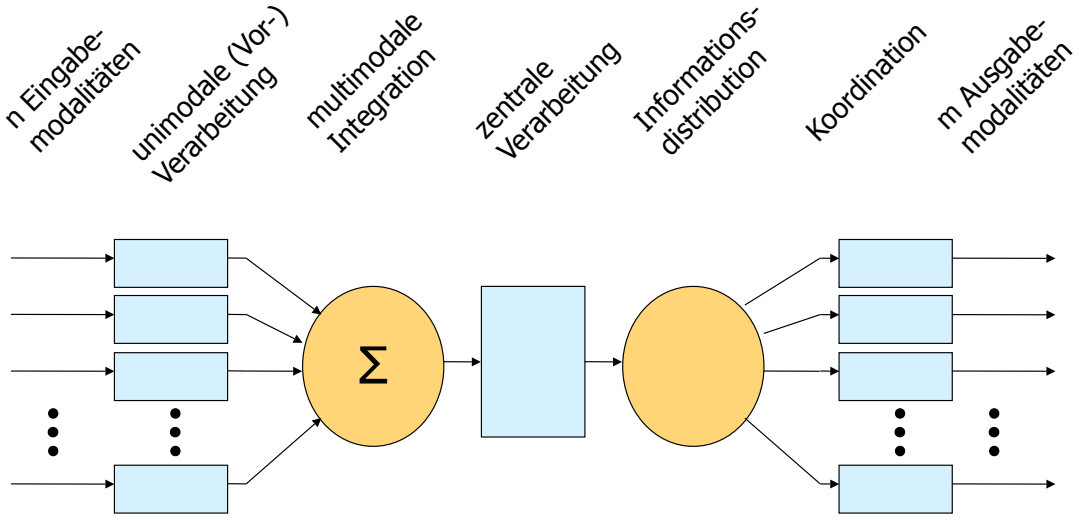

Verarbeitungsschema für multimodale Systeme

Multimodale Systeme: Beispiele

Spracherkennung + Lippenlesen

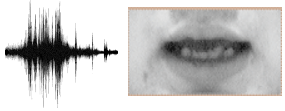

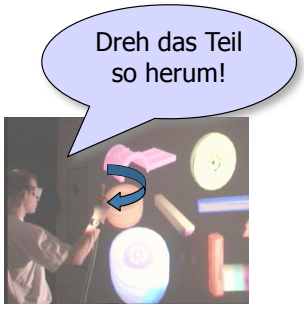

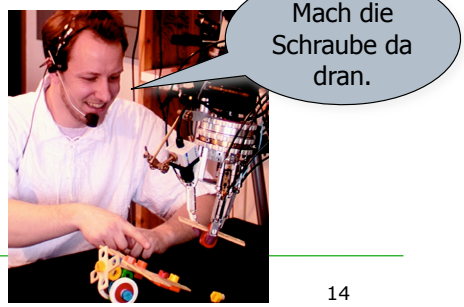

Multimodal Interfaces vs. GUIs

GUIs

1. Assume that there is a single event stream that controls event loop with sequential processing
2. Assume interface actions (e.g. selection of items) are atomic and unambiguous
3. Separable from application software and resides centrally on one machine
4. No temporal constraints, architecture not time sensitive

Multimodal Interfaces

1. Typically process continuous and simultaneous input from parallel incoming streams
2. Process input modes using recognition-based technology, good at handling uncertainty and ambiguity
3. Large computational and memory requirements, typically distributed (e.g. multi-agent systems)
4. Require time stamping of input and development of temporal constraints on mode fusion operations

Sprache

- *symbolische* Modalität: sprachliche Zeichen bezeichnen nur aufgrund von Konventionen
  - Ausnahme: *Onomatopoetika* (Lautmalerei)
- (gesprochene) Sprache umfaßt weitere nichtsymbolische Information: Prosodie

(in der VL bereits behandelt)

Lippenlesen

- Sprechbewegungen des Mundes
- Ausgenutzt zur Verbesserung der Spracherkennung, vor allem bei Hintergrundgeräuschen (z.B. im Auto)
  - Erinnerung: „McGurk-Effekt“

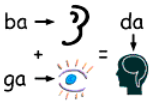

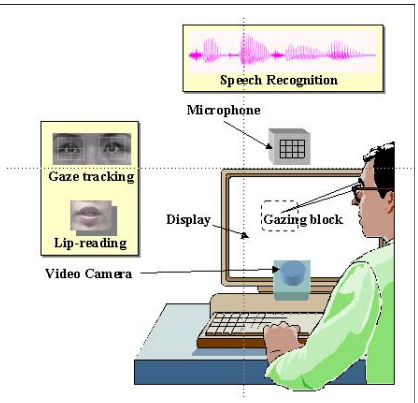

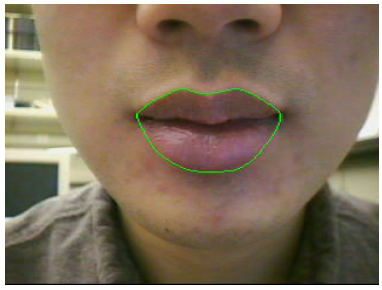

Bimodal speech rec.,
Rockwell Scientific Comp.

Gestik

- *Kommunikative* Gestik
  - Nicht manipulativ (z.B. Haare aus Gesicht streichen)
  - Unmittelbar bedeutsam (z.B. nicht nervöses Wippen)

Gesten sind Bewegungen der oberen Gliedmaße,
die aufgrund einer Kommunikationsabsicht entstanden sind.

ikonische Geste
äußere Form der Geste ähnelt dem Objekt

indexikalische (deiktische) Geste
verweist auf ihr Objekt im Kontext

symbolische (emblematische) Geste
konventionalisiert innerhalb einer Gemeinschaft

Gesten: Struktur

Gesten bestehen typischerweise aus mehreren Bewegungsphasen

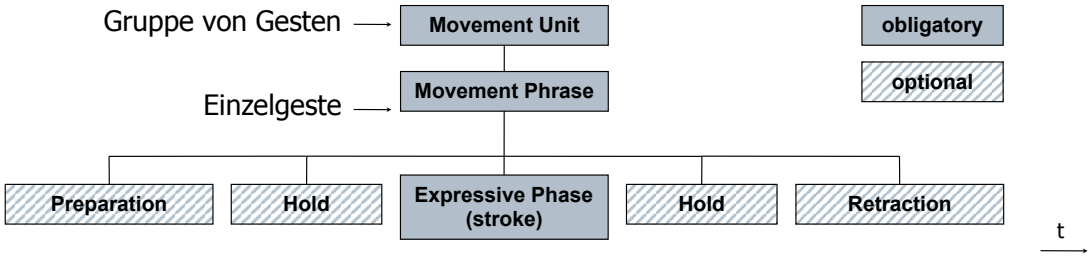

- Vorbereitungsphase (preparation): Hände in Stellung bringen
- expressive Phase (stroke): bedeutungstragender Teil
- Rückführungsphase (retraction): Hände zurück in eine Ruhestellung
- Haltephasen (hold): keine Bewegung

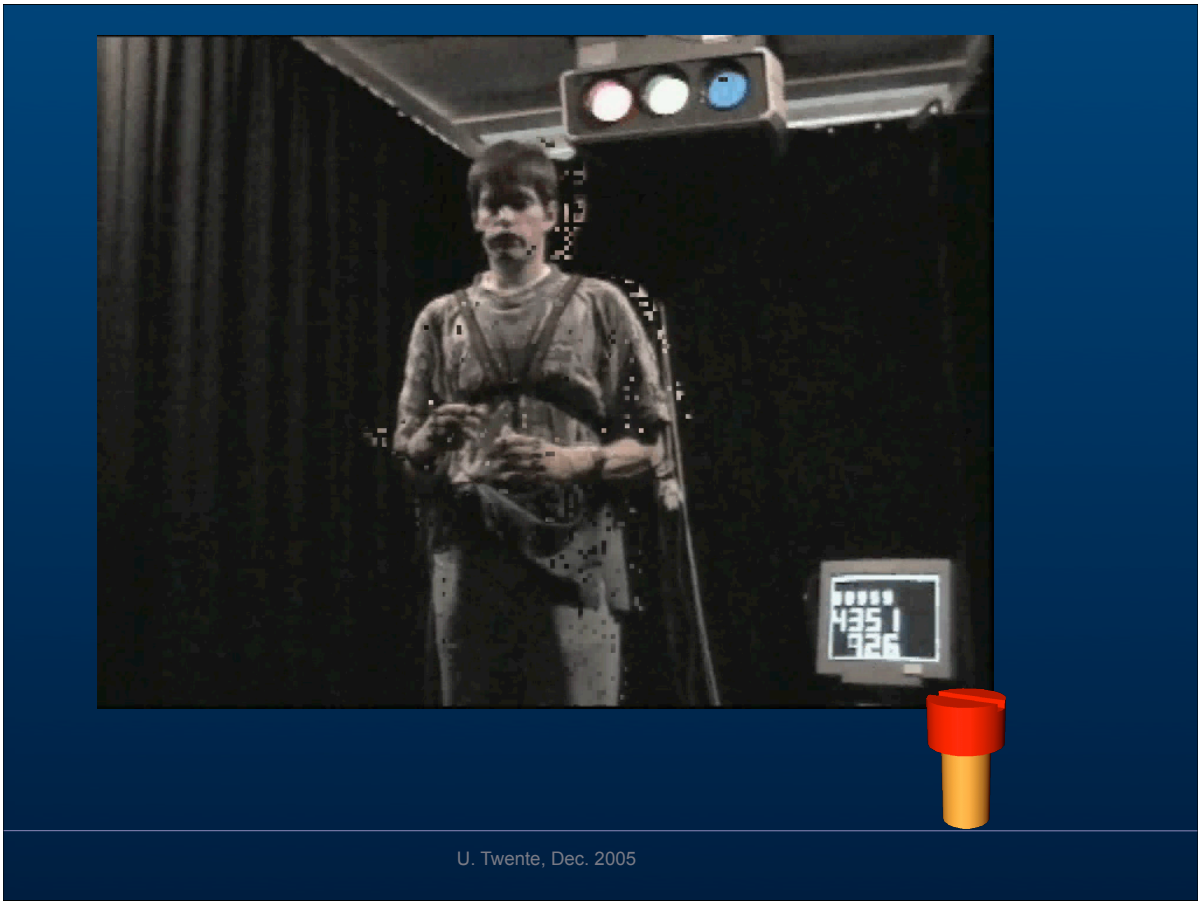

Other functions of gesture

Reflect discourse structure

- Convey, and thus mark, discoursively focal elements
- Emphasize
  - Beats or beat-like movement qualities

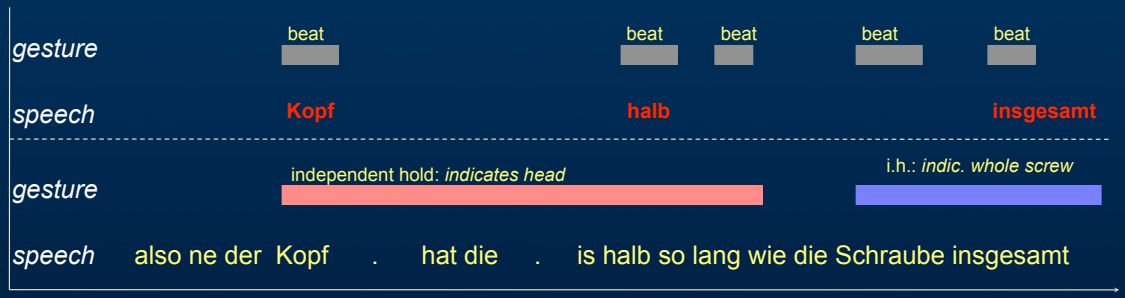

Gestenerkennung

- Techniken: kamerabasiert, aktives Tracking (Datenhandschuhe, Sensoren) oder passives Tracking (markerbasiert) (siehe VL zu „Input Devices“)
- *Segmentierungsproblem*:
  Wie können aus dem Bewegungsfluß die *Strokes* segmentiert werden?
- Möglichkeiten: Ausnutzung von Merkmalen wie Handspannung, Symmetrien, Stopps, etc.

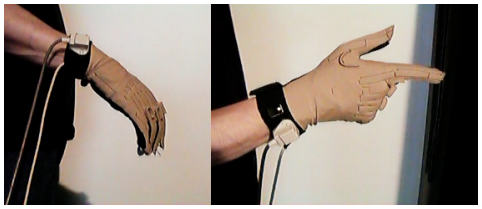

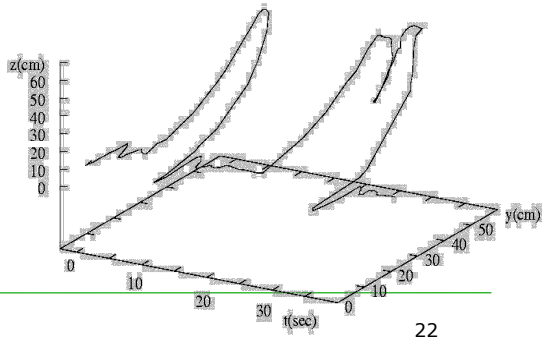

Natürliche Multimodalität: Gestik und Sprache

Zwischen Sprache und Gestik besteht ein zeitlicher und inhaltlicher Zusammenhang – zusammengefaßt in drei "Regeln" (McNeill, 1992):

- Phonologischer Synchronismus
  Der *Stroke* einer Geste eilt der betonten Silbe voraus oder ist mit ihr synchronisiert.
- Semantischer Synchronismus
  Sprache und Gestik stellen dieselbe Bedeutung zur selben Zeit dar.
- Pragmatischer Synchronismus
  Wenn Sprache und Gestik gemeinsam auftreten, dann erfüllen sie dieselbe pragmatische Funktion.

Gestik und Sprache

Die starke Verzahnung von Sprache und Gestik führte zu der Theorie, daß koverbale Gestik und Sprache einer gemeinsamen kommunikativen Grundidee entspringen.

Vorstellung

Kommunikation: Abfolge von zu kommunizierenden Inhalten oder Gedanken. Gedanken entwickeln sich dann zu (oder werden verpackt in) Sprache und Gestik.

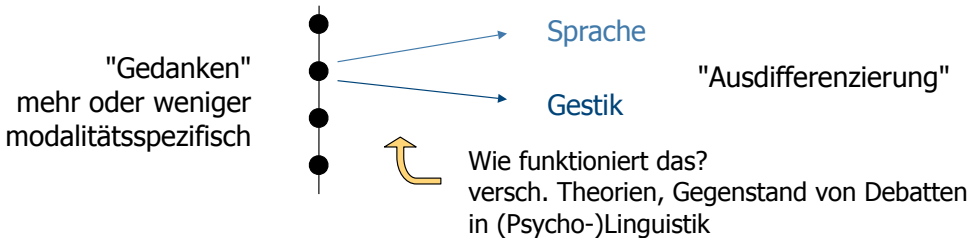

Overall production of speech and gesture

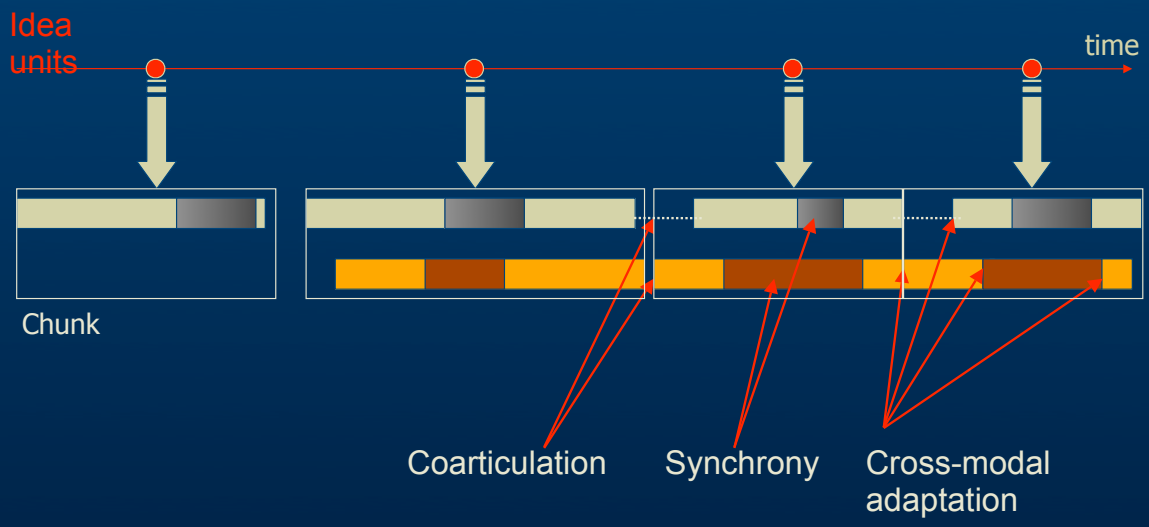

U. Twente, Dec. 2005

Mimik

Lexikondefinition (Duden)

"Gebärden- und Mienenspiel [des Schauspielers] als Nachahmung fremden oder als Ausdruck eigenen seelischen Erlebens"

Biologisch

- Verschiebung der Gesichtshaut durch das Zusammenspiel verschiedener Muskeln
- auch bei anderen Primaten ausgeprägt, aber Menschen haben leistungsfähigste Mimik (feinere Muskeln als z.B. Schimpansen

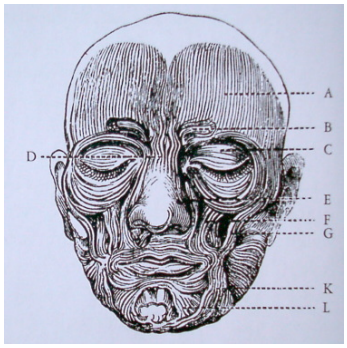

Mimik: Emotionaler Ausdruck

Mimik trägt zum Ausdruck *emotionaler Zustände* und kommunikativen Feedbacks bei

- Darwin:
  - Kleinkinder: Wut, Angst, Zuneigung, Freude, Neid, Schüchternheit, Unbehagen
  - + bei älteren Kindern "kognitivere" Emotionen: Scham, Trauer, Verlegenheit, Resignation
- Heute in der Regel 6 „Grundemotionen"
  - Freude, Trauer, Ekel, Überraschung, Wut, Angst
  - Die Mimik dazu ist bei allen Menschen gleich

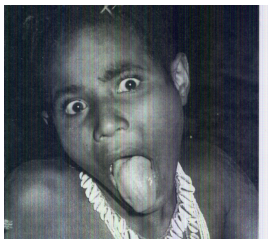

Abb.: Schiefenhövel et al., 1994

Mimikerkennung

- Gesichtserkennung im Videobild
- Merkmalsextraktion: Finden bestimmter Strukturen (Augenbrauen, Augen, Nase, Mund) und Bestimmung markanter Punkte darauf
- Klassifikation der Gesichtsmimik: häufig auf Basis der Bewegungen der markanten Punkte relativ zueinander
  - Klassifikation in Emotionen (freudig, ärgerlich, …) oder
  - Klassifikation in aktivierte Aktionseinheiten

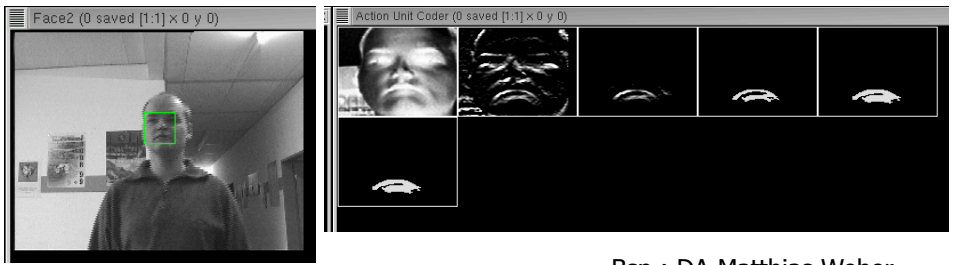

Bsp.: DA Matthias Weber

Mimikerkennung

- *Facial Feature Finding & Tracking*

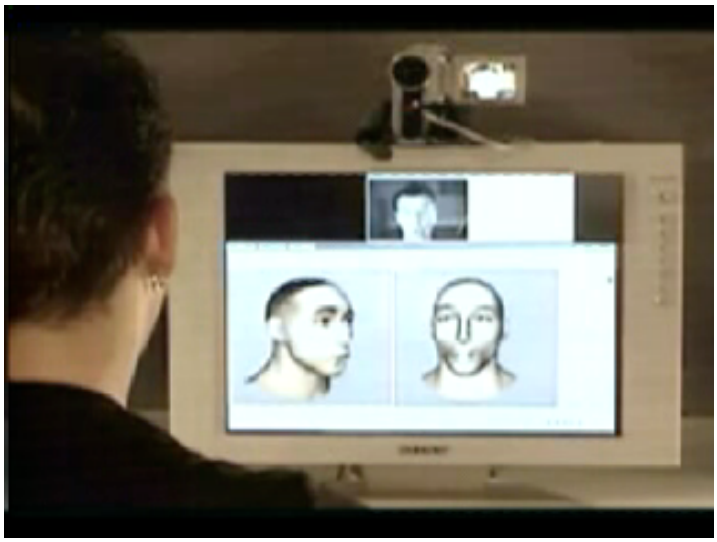

www.nevenvision.com

Blickrichtung

- kann als "eigene" Modalität angesehen werden
- wichtig zur Aufmerksamkeitsfokus-Bestimmung oder zur Dialogsteuerung (*Turn-Taking)*
- kann interne Zustände widerspiegeln:
  - Augen beim Gespräch nach oben: nachdenken oder Gedächtnisinhalte abrufen
  - Augen nach oben + leicht geöffneter Mund: "was für ein Idiot…"

Multimodal input processing

- The processing and integration of multiple input modalities for the communication between a user and the computer.

- Examples:
  - Speech and pointing gestures (Put-That-There, CUBRICON, XTRA, etc.)
  - Eye Movement based Interaction (Jacob, 1990)
  - Speech, gaze and hand gestures (ICONIC, Virtuelle Werkstatt)
  - Speech and Lip Movement

MIT Media Room

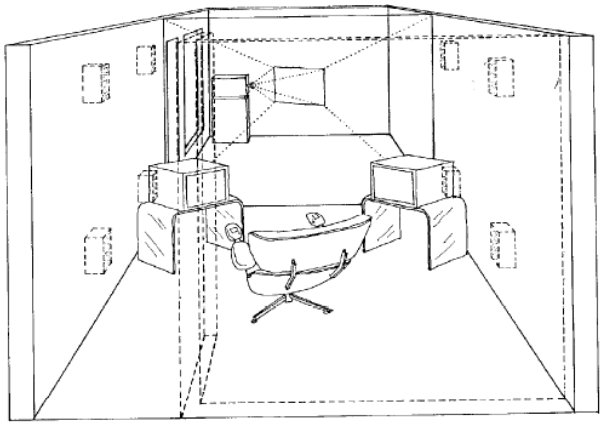

- loudspeakers, frosted glass projection screen, TV monitors on either side of user's chair
- chair arms with one-inch high joystick sensitive to pressure and direction, touch sensitive pad
- Position-sensing cube attached to wristband

Put-That-There (Bolt, 1980)

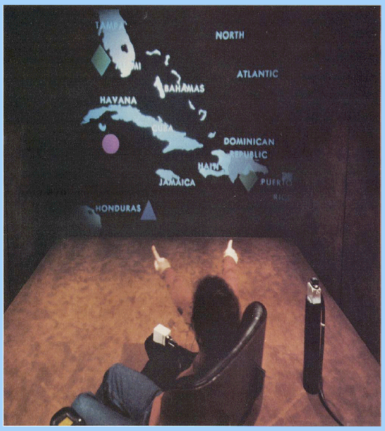

(Graphic taken from [1])

"Create":
"Create a blue square there."

"Move":
"Move the blue triangle to the right of the green square"
"Move that there"
(User does not even have to know what "that" is.)

"Make that …":
"Make that blue triangle smaller"
"Make that smaller"
"Make that like that"

"Delete":
"Delete that green circle"
"Delete that"

Processing of commands

"Create a blue square there."

→ Effect of *complete* utterance is a "call" to the *create* routine that needs the object to be created (with attributes) as well as x,y position input from wrist-borne space sensor.

"Call that …the calendar"

→ Recognizer sends code to host system indicating a naming command ("call") → x,y coordinates of item signal are noted by host → host switches speech recognition to training mode to learn the (possibly new) name to be given to the object

All utterances processed with hard-wired procedural semantics

Multimodal analysis (revisited)

Two central problems to be solved (Srihari, 1995):

segmentation problem

how can a system be made to cope with `open input´? how can continuous input be segmented into units that can be processed in one system cycle?

correspondence problem

how to determine what relates to what across the multiple input modalities?

Multimodale Integration (Fusion)

- Zu beachten:
  - zeitliche Zusammenhänge
    Bsp.: *"stell dieses <Zeigegeste> Ding dort hin"*
    → Bezieht sich die Geste auf das Objekt (dieses) oder den Ort (dort)?
  - Semantisch-pragmatische Zusammenhänge
    Bsp: „drehe diese <ikonische Geste> Leiste so herum"
    → Geste deute Drehung an, bezieht sie sich auf Objekt oder Aktion?
- Typische Methode: Übernahme und Erweiterung von Techniken aus dem Bereich des Parsens natürlicher Sprache (*"Multimodale(s) Grammatik/Parsen")*

Integration mit Framestrukturen

- Modellierung einer Benutzerinteraktion als eine *Frame* mit festen *Slots* von Attribut-Wert-Paaren
- Modalitäten können einen oder mehrere *Slots* füllen bis Struktur komplett spezifiziert ist
- Nachteil: feste Struktur; erlaubt nur einen Typus von Interaktion

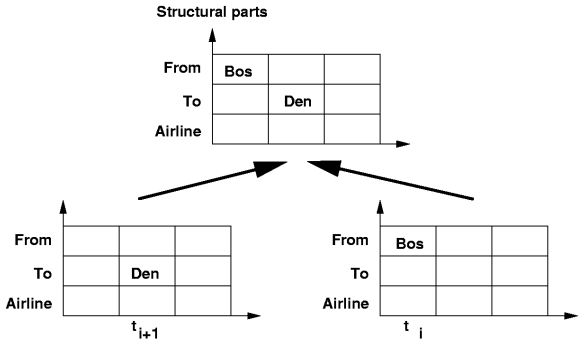

Beispiel: **MATIS**, **M**ultimodal **A**ir **T**ravel **I**nformation **S**ystem

(„Melting pots")

Integration mit getypten Attribut-Wert-Strukturen

- im Gegensatz zu starren Frame-Strukturen Einführung unterschiedlicher Frame-Typen
- Integration durch Unifikation der Strukturen

Beispiel: **QuickSet**, multimodales System für "command-and-control"

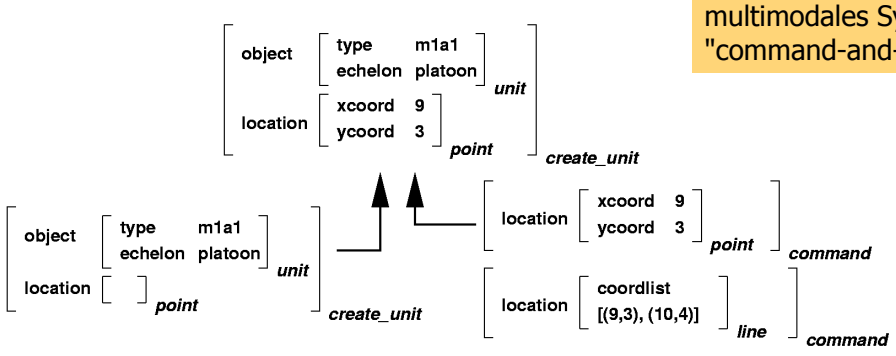

from speech

from pen/map

Integration mit Automaten/ Übergangsnetzen

- Parsen eines multimodalen Ausdrucks durch Zustandsübergangsnetze (STN, ATN)
- Alphabet der Eingabesymbole z.B.: Menge von Worten und Menge verschiedener Gesten
- Problem: Im Gegensatz zu Sprache sind multimodale Eingaben (etwa Sprache und Gestik) nicht sequentiell; Möglichkeiten zur Flexibilisierung der starren Abfolge von Eingabezeichen nötig

Beispiel: **tATN**

„Rotate [pointing] this thing about 30 degrees to the right."
„Rotate the yellow wheel like [rotating] this."

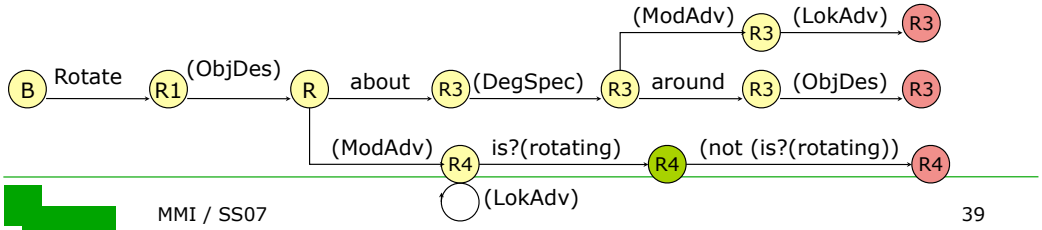

(Latoschik, 2001)

CUBRICON (Neal & Shapiro, 1991)

- System integrating deictic and graphic gestures with simultaneous NL for *both* user input and system output
- interface capabilities
  - Accepts and understands references to entities in NL & pointing
  - Disambiguates unclear references and infers intended referent
  - Dynamically composes and generates synchronous spoken NL, gestures and graphical expressions in output

Calspan-UB Research Center Intelligent CONversationalist

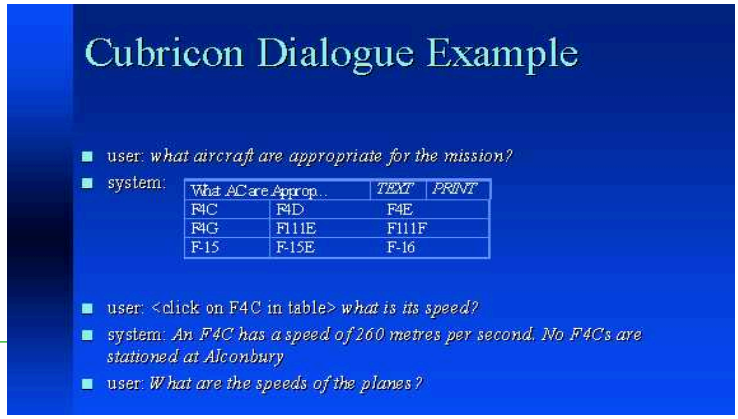

CUBRICON Knowledge Sources

- Multimedia parser: ATN network for NL + mouse gesture
- Used in understanding input and generating output
- Knowledge Sources:
  - Lexicon
  - Grammar: defines multimodal language
  - Discourse Model: Representation of "attention focus space" of dialogue. Has a focus list and display model – tries to retain knowledge pertinent to the dialogue
  - User Model: Has dynamic "Entity Rating Module" to evaluate relative importance of entities to user dialogue and task – tailors output and responses to user's plans, goals and ideas
  - Knowledge Base: Information about task domain, all objects and concepts represented in a single knowledge representation language (semantic net-based)

ICONIC (Koons et al., 1993)

- Integrating simultaneous speech, gestural, and eye movement (for reference resolution for map and blocks world interaction)
- Problems: timing and abstraction
  - All three streams of data are collected on a central workstation and assigned time stamps, used later to realign data

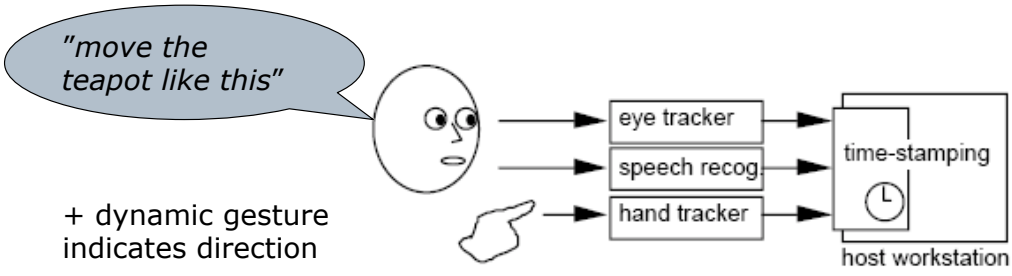

ICONIC: Processing input streams

Step 1 - Parsing

- Parse input data stream
- Generate frame-based description of the data

Step 2 - Evaluation

- Encode and evaluate the frames based on two models
- Every frame has method that controls search for frame values in KB

- Knowledge base spans two interconnected representational systems, objects are represented in both
  - categorical system (semantic network)
  - spatial system (locations)

ICONIC: Evaluation

"…below the red triangle"

- Finds values for each frame in space/category systems
- Integrates spatial values from speech, gesture, eye

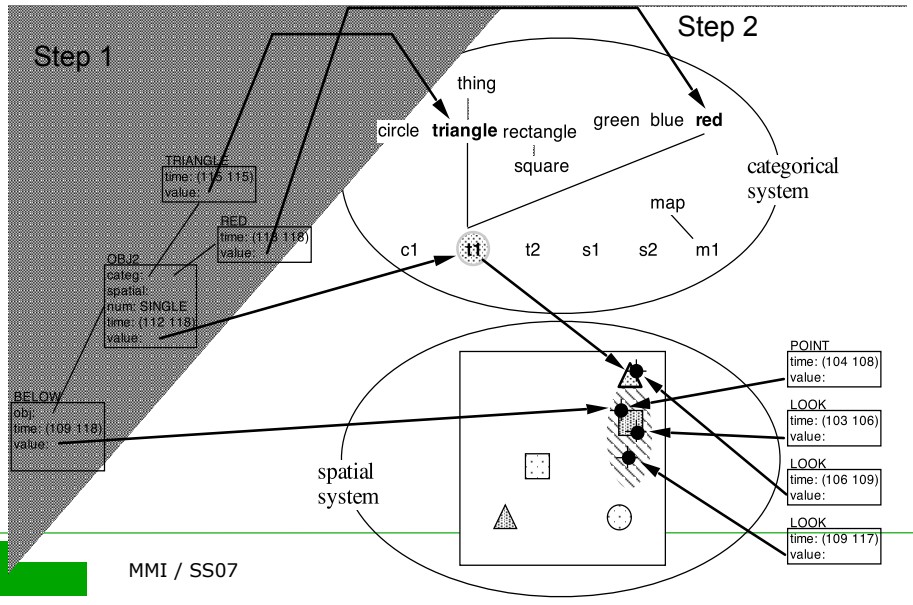

ICONIC System

- Processes speech and gesture parallel (deictic, iconic and panomimic gestures)
- Speech-driven:
  - Whenever speech suggests possibility of a gesture (e.g. "that", "like this"), system looks for appropriate segment
  - Tested on ambiguity of language, whether gestures can dissolve this.
- *iconic mapping*
  - Iconicity evaluated for hand posture, gestlets transformed to shape description
  - correlated to shape of objects referenced verbally

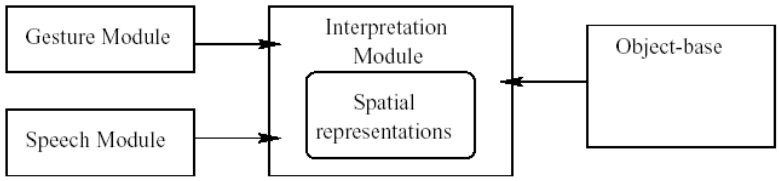

Shape-related expressions (Sowa)

- translate gesture features into spatial representation of shape
- not limited to a single gesture, properties may accumulate over a series of movements and postures
- match shape representation with system's representation of how the objects look like

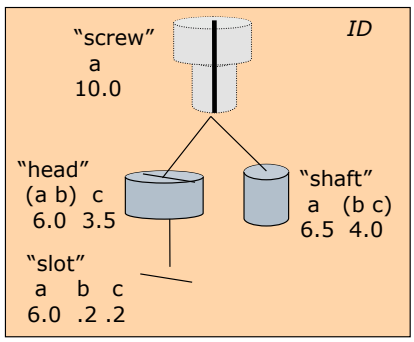

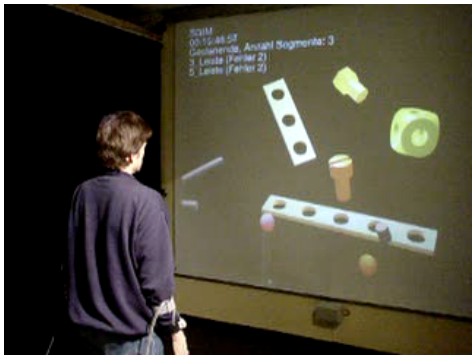

Model overview

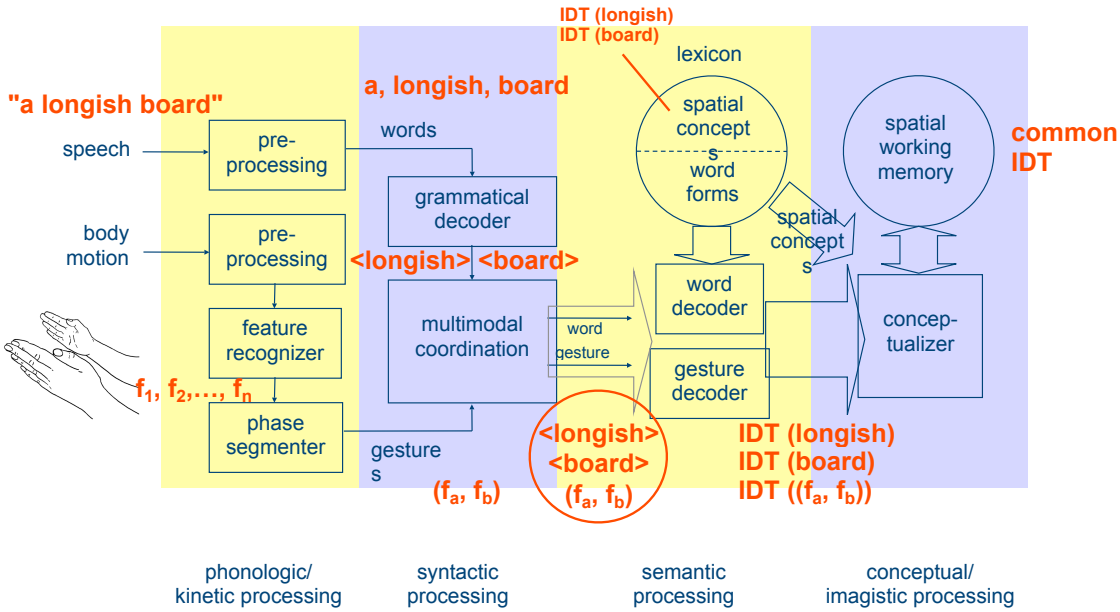

Multimodale Ausgabe (fission)

Zwei Ansätze zur Generierung multimodaler Ausgaben:

- "Klassische" Multimediasysteme:
  Informationen können über verschiedene Modalitäten oder eine Kombination von Modalitäten präsentiert werden. Es kommen die "üblichen" vom Desktop-Rechner gewohnten Modalitäten zum Einsatz: *Text, Grafik, Animation, Ton*

- Anthropomorpher Ansatz:
  Das System wird durch eine humanoide Figur als Kommunikationspartner verkörpert, oder dem System wird eine Figur als "Helfer" zur Seite gestellt.
  Hier stehen die natürlichen Modalitäten im Vordergrund:
  Sprache, Gestik, Mimik, Körperhaltung

Multimedia Presentation Generation

"No Presentation without Representation"

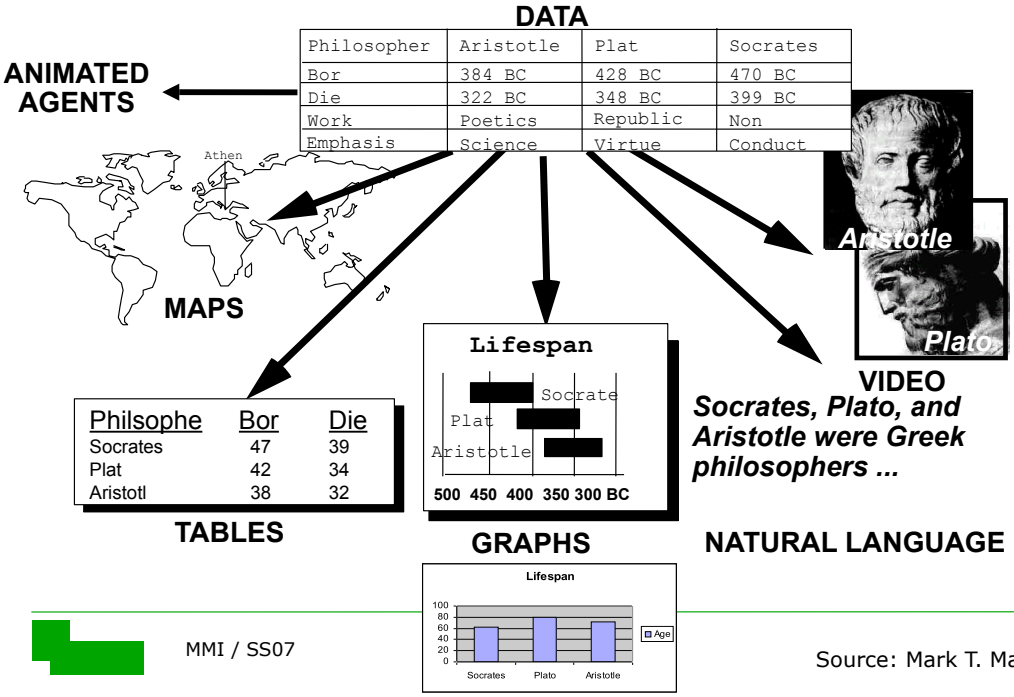

Source: Mark T. Maybury

Common Presentation Design Tasks

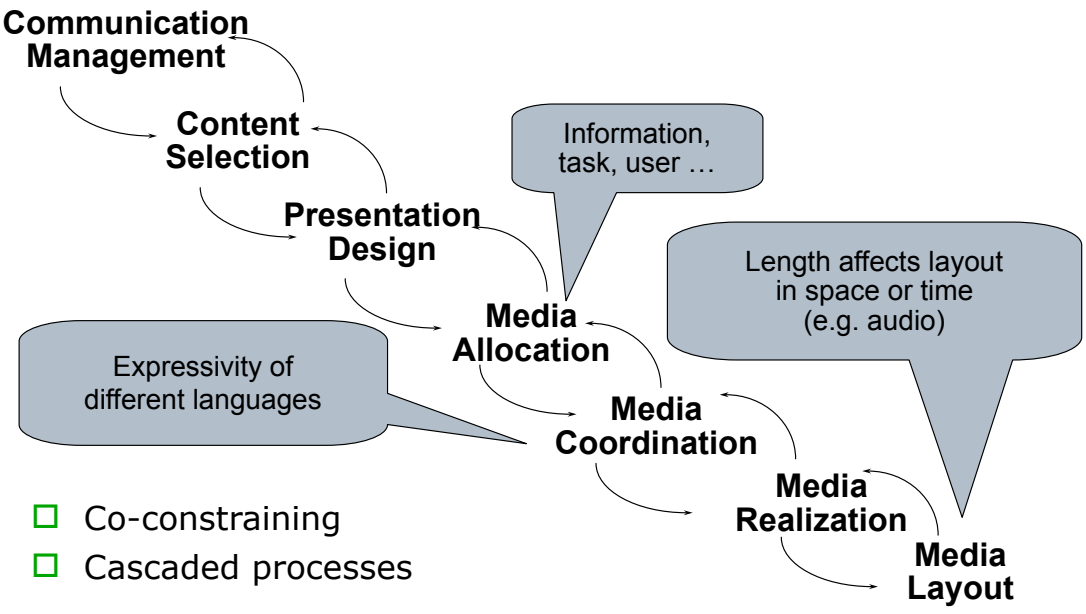

- Co-constraining
- Cascaded processes

Source: Mark T. Maybury

COMET (**Co**ordinated **M**ultimedia **E**xplanation **T**estbed; Feiner et al. 1993)

- System erklärt den Diagnosevorgang bei technischen Problemen mit Funkgeräten
- erst Bestimmung *was* das System ausdrücken will, dann Planung *wie* dieser Inhalt möglichst passend übermittelt wird

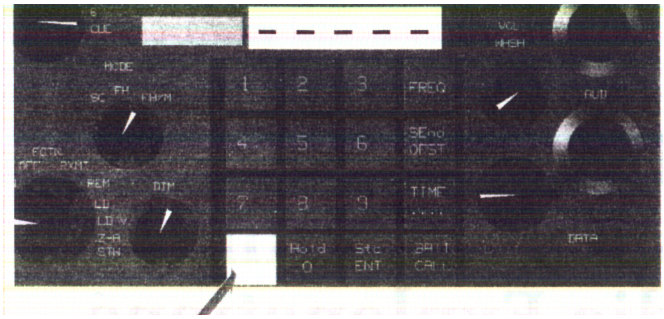

Press the CLR button to clear the display

Media coordination in COMET

Entscheidet heuristisch, welche Information in welcher Modalität dargestellt wird

- Klassifikation der Informationen in 6 Informationstypen in der ‚logical form' für Text vs. Grafik:
  - Lokation, physische Attribute (Form etc.) → nur Grafik
  - abstrakte Aktionen und Zusammenhänge zwischen Aktionen (Reihenfolge, Kausalität) → nur Text
  - konkrete Aktionen → Grafik + Text

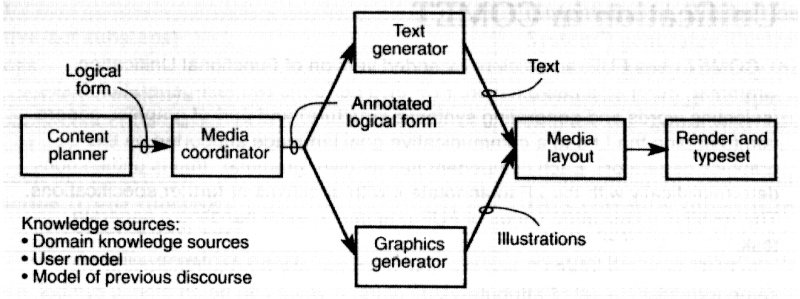

WIP: Use of communicative acts

- Integrated planning process to create document plan
- Use of repository of communicative acts (cf. speech acts)
- Goal-refinement into subgoals
  - communicative (e.g., describe)
  - textual (e.g., S-request)
  - graphical (e.g., depict)

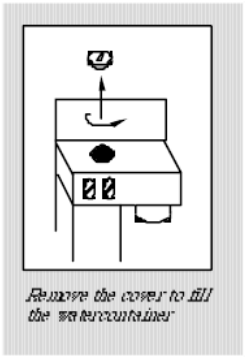

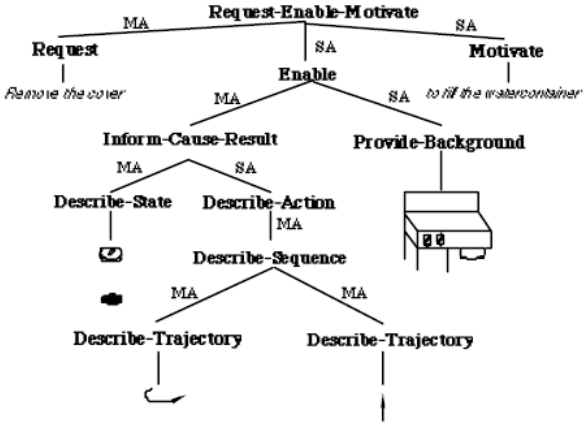

Wahlster et al., 1993;
Andre & Rist, 1993

Agent-based interfaces
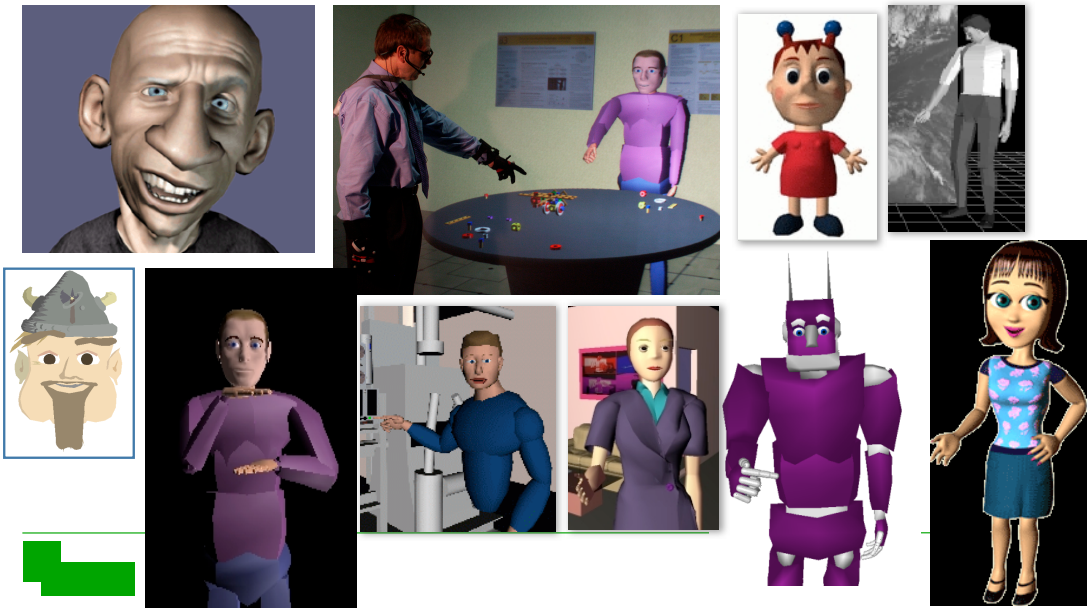
- Natürliche Interaktion mit „natürlichem" Gegenüber