

Praktikum Ubiquitous Computing

WS06/07



Michael Beigl

TU Braunschweig

Institute of Operating Systems
and Computer Networks

www.ibr.cs.tu-bs.de/dus

Einführung Interaktion

Interaktion in Ubiquitous Computing

- Veränderte Zielgruppe: „Consumer“ statt „User“
- keine Computererfahrung vorausgesetzt:
 - **Hide the computer**
- Disaggregierte Zugangsschnittstelle
 - **Auch ein Vorteil!**
- **Einfachheit, minimaler Lernaufwand**
 - insbesondere bis zur ersten erfolgreichen Nutzung

Gestaltung

Affordance Konzept

Etwas Mensch-Maschine Interaction:

James Gibson, 1977: the theory of affordances

- Beeinflußt von Gestalt Theorie, aber „ecologischer“ (Entdecker-) statt konstruktivistischer Ansatz

Gestalt Theorie

- Menschen erkennen die Dinge/Abläufe im Zusammenhang und interpretieren diese innerhalb des aktuellen Kontextes
- Beschreibt, wie Dinge als zusammengehörig empfunden werden
- **Proximity**: Räumliche Nähe von Dingen
- **Similarity**: Ähnlichkeit im Aussehen, Bedienung, Kontext,...
- **Closure**: Im Zusammenhang nützlich
- **Simplicity**: Wenn sie zusammen ein vereinfachtes Bild abgeben

Gestaltung Affordance Konzept

Don Norman

- Human-centered design:
“The Design of Everyday Things”, 1988
- *affordance* refers to the perceived and actual properties of the thing



Quelle: jnd.com

Idee

- Bringe empfundene (perceived) und tatsächliche Eigenschaften (actual properties) in Einklang

3 Prinzipien zur Gestaltung

- Mache nutzbare Eigenschaften sichtbar
- Benutze “natürliche” Assoziationen zur Verdeutlichung
- Gib “Feedback”




Wer hat sich das angesehen???

Marktanalyse, Related Work!!

Tangible Media

- Ausgangspunkt: GUIs bestehen aus „painted bits“
- Stattdessen Interfaces aus „tangible bits“
- Direktere Manipulation, „Begreifbarkeit“
- Nutzung der Fähigkeit des Menschen, physische Umgebungen zu manipulieren
- Nutzung von Design Affordances, s.u.
- Vision und Beispiele s. <http://tangible.media.mit.edu/>





Kontexterkennung

- **Neuronale Netze**
- **Bayes Klassifikation**


Neuronale Netze

Künstliche Neuronale Netze (KNN)

- Übertragung Informationsverarbeitung des menschlichen Gehirns auf Computersysteme
- Neuronen:
 - kleinste informationsverarbeitende Einheit
 - miteinander über Kommunikationskanäle verbunden, um gemeinsam komplexe Aufgaben zu lösen
- Lernfähig, fehlertolerant, Generalisierungs- und Assoziationsfähigkeit
- Wichtige Anwendungsfelder: Mustererkennung, Klassifikation, Funktionsapproximation, Sprachanalyse

Neuronale Netze


Aufbau



- Aktivierungsfunktion:
$$a_j(t) = \begin{cases} 1 & \text{falls } net_j(t) \geq \theta_j, \\ 0 & \text{sonst.} \end{cases}$$
- Ein/Ausgabe Funktion:
$$net_j(t) = \sum_i o_i(t)w_{ij}$$
- **Lernen:** Adaption der Gewichte w_{ij} , um ein Eingabe auf Ausgabe anzupassen (Lernfkt.), benutze Trainingsdatensatz
- **Testen:** Verifikation der gelernten Struktur durch Testdatensatz verschieden von Trainingsdatensatz

Neuronale Netze

Aufbau



Ausgabeschicht
(output layer)

0 bis n verdeckte
Schichten
(hidden layers),

Eingabeschicht
(input layer)

- **Neuronales Netz,
Schichten**

Neuronale Netze

Lernen

Überwachtes Lernen (supervised learning)

- Bei diesen Lernverfahren wird auf eine Eingabe eine gewünschte Ausgabe dem Netz als Information zugeführt.

Bestärkendes Lernen (reinforcement learning)

- Diese Verfahren arbeiten mit belohnen und bestrafen des Netzes. Wird eine Ausgabe produziert, so bekommt das Netz als Information nur, ob diese Ausgabe richtig oder falsch ist.

Unüberwachtes Lernen (unsupervised learning)

- Hier bekommt das Netz keinerlei Informationen über die Richtigkeit seiner Ausgabe. Diese Verfahren arbeiten nach der Methode der Clusterbildung, wobei ähnliche Daten auf gleiche Cluster abgebildet werden.

Neuronale Netze


Lernen / Self-Organizing-Maps (SOM)

Self Organizing Maps (SOMs), Kohonen Maps

- Entwickelt von Teuvo Kohonen (Finnland)
- Weiterentwicklung von Learning Vector Quantization (LVQ)
- Unsupervised Learning

LVQ

- Abbildung der Eingabe auf Neuronen über Codebookvector (= Gewichte)
- 1. Gewinner: Neuron mit kleinstem (eukl.) Abstand zur Eingabe
- 2. Modifikation der Gewichte (Lernfkt.)



Abstandsberechnung:

$$o_i = \arg \min_j \left(\sqrt{\sum_{i=1}^n |x_i - w_{ij}|^2} \right)$$

Neuronale Netze

Lernen / Self-Organizing-Maps (SOM)


LVO → SOM

- Adaption der Gewichte von Nachbarneuronen des Gewinnerneurons
- Lernfunktion $\forall j : w_{ij}(t) = w_{ij}(t-1) + \alpha(t) \cdot \eta(t') \cdot (x_i(t) - w_{ij}(t-1))$
- Alpha: Funktion über die Lernrate
- Eta: Nachbarschaftsfunktion
- Beiden sollten monoton fallend sein, da sonst Übertrainierung

Klassifikation

- Zuweisung des Label des Inputvektors (Laufen, Stehen, ... allg. Kontext) zu einem Gewinnerneuron
- Weitere Möglichkeit: Clustere Gewinnerneuronen (k-means),
→ Kontext = Cluster

Beispiel



Quelle: [Teaching Context to Applications](#), K. Van Laerhoven and K. A. Aidoo. In Personal and Ubiquitous Computing: Situated Interaction and Context-Aware Computing, 2001

Neuronale Netze

Bewertung

Probleme

- keine eindeutigen Vorschriften bei Netzwahl (Dimension, Anzahl der Neuronen, ...)

Lernverfahren

- Schwierigkeiten beim Finden der optimalen Parameter (plasticity-stability dilemma, Übertrainierung)
- Großer Rechenaufwand im Training

sinnvolle Verwendung

- Gut in Kombination mit anderen Verfahren, z.B. Markov-Ketten, Fuzzy-Systemen, Bayes-Netzwerke

Bayes Klassifikation

- Angabe von Ereignissen über bedingte Wahrscheinlichkeiten

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

- $P(A)$ die A-Priori-Wahrscheinlichkeit für ein Ereignis A
- $P(B | A)$ die Wahrscheinlichkeit für ein Ereignis B unter der Bedingung, dass Ereignis A auftritt
- $P(B)$ die A-Priori-Wahrscheinlichkeit für ein Ereignis B

- **Lernen:** Bestimmung der Wahrscheinlichkeiten durch Auszählen aus den Messdaten

Bayes Klassifikation

Bayes Gesetz für Kontexte angewandt

$$P(\text{Context}|\text{Sensorvalue}) = \frac{P(S|C)*P(C)}{P(S)} = \frac{P(S|C)*P(C)}{P(S|C)*P(C)+P(S|\neg C)*P(\neg C)}$$

Klassifikation

- $\max\{P(\text{Context}|\text{Sensorvalue})\}$, für alle Context
- Problem: Wer sagt uns, dass die Trainingsmenge ausreichend war?
- Vorteil: Nur wenige Parameter (Wahrscheinlichkeiten) müssen gespeichert werden, einfache Berechnung der Wahrscheinlichkeiten

Bayes Vorgehen

Optionen

- Wahrscheinlichkeiten, bedingte Wahrscheinlichkeiten von Experten bestimmen lassen
- Wahrscheinlichkeiten anhand von Trainingsdatensatz lernen

Lernen z.B.


- Bilde eine Messreihe
- Stelle zu erkennenden Kontext (Hypothese) / nicht zu erkennenden Kontext fest und korreliere zu messenden dann den Sensorwert -> $P(S|C)$, $P(S|\neg C)$, $P(C)$, $P(\neg C)$

Grundsaltungen

Spannungsregelung

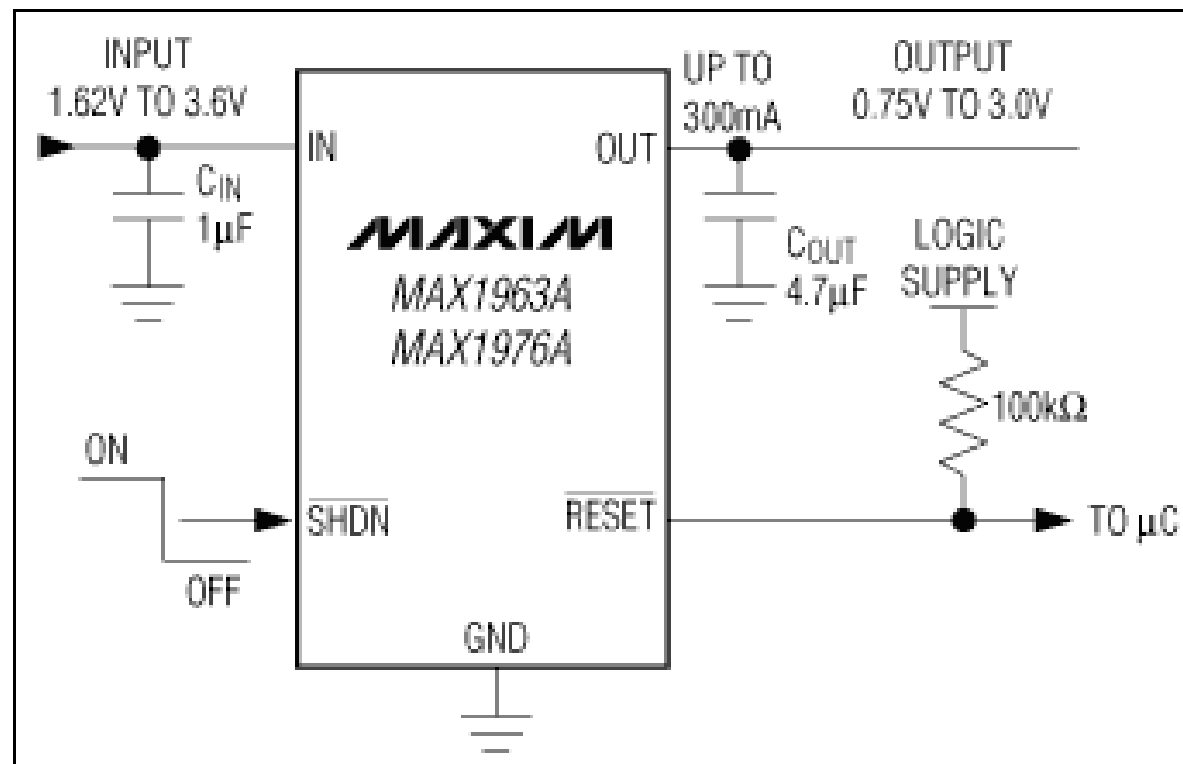
- Regler (regulator)
- Stepper (up, down)

- **Regler**
 - Immer von höherer nach niedrigerer Spannung
 - Regelt Spannungsdifferenz durch Umsetzen in Wärme ($\Delta V \cdot I$), braucht Kühlung
 - Spannungsverlauf sehr linear, kein „Ripple“
 - Braucht höhere Eingangsspannung als Ausgangsspannung
 - Low Dropout Regulator (LDO):
Differenz kann sehr klein sein (typ 0.3-0.6V)
- **Stepper (Up, Down)**
 - Kann entweder von hoher nach niedriger Spannung oder umgekehrt arbeiten




Spannungsreglerschaltung

- Kondensatoren am Ein- und Ausgang notwendig, um Stromspitzen abzufangen
- ... Da Regler nicht beliebig schnell nachregulieren kann!
- Typ. Bsp:



Step-Up / Down

- Konvertiert Spannung nach oben / unten
- Durch „Hochpumpen“: hier C2 wird ständig nachgeladen, Output überwacht
- Boost-Step-Up: Spannungsüberhöhung durch Schaltung der Spule: „Aufladen“ mit Energie von Quelle, Entladen über Kondensator
- Immer mit „Ripple“ verbunden!!!



Operation Amplifier

Op-Amp

- Verstärkerbaustein
- Normalerweise Differenziell (+, -, GND als Spannungsquellen -> nicht optimal für kleine Sensorboards
- Besser: „Single Supply“ Op-Amps
- Einfach: „Diskrete“ Werte Verstärken
- Falls Frequenz eine Rolle spielt (z.B. Micro/Audiosignal): Bandbreitenprodukt wichtig.
- Bandbreitenprodukt: Verstärkungsleistung * Frequenz
- Je höher Bandbreitenprodukt, desto teurerer, energiehungriger Schaltung/Chip