
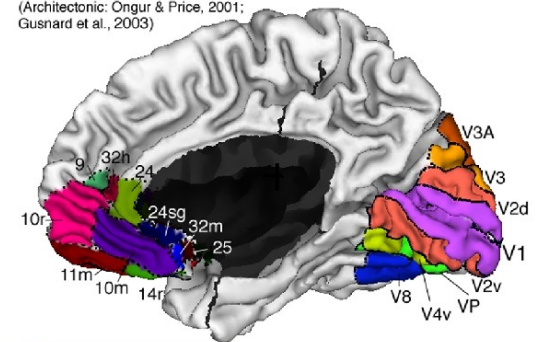


Computer Vision Workshop

MetaLab, 02.07.2010



Orbito-frontal areas
(Architectonic: Ongur & Price, 2001;
Gusnard et al., 2003)



Visuotopic areas
(fMRI: Hadjikhani et al. 1998;
Tootell & Hadjikhani, 2001;
Press et al., 2001;
Van Essen, 2003)

Dr. Alexander K. Seewald



Übersicht

Einleitung - Das menschliche Sehsystem & OpenCV

Anwendungs- & Demosession

- Test vortrainierte BDTHF Modelle
- Low-cost Eyetracking (BDTHF in OpenCV)
- Boosted DecisionTrees of Haarlike Features (BDTHF)



- Test Magazinseiten-Erkennung emedia
- Magazinseiten-Erkennung (SIFT/SURF in OpenCV)
- Scaled Invariant Keypoint Transform (SIFT)

Eyetracking Testaufnahmen

The Human Visual System (1)

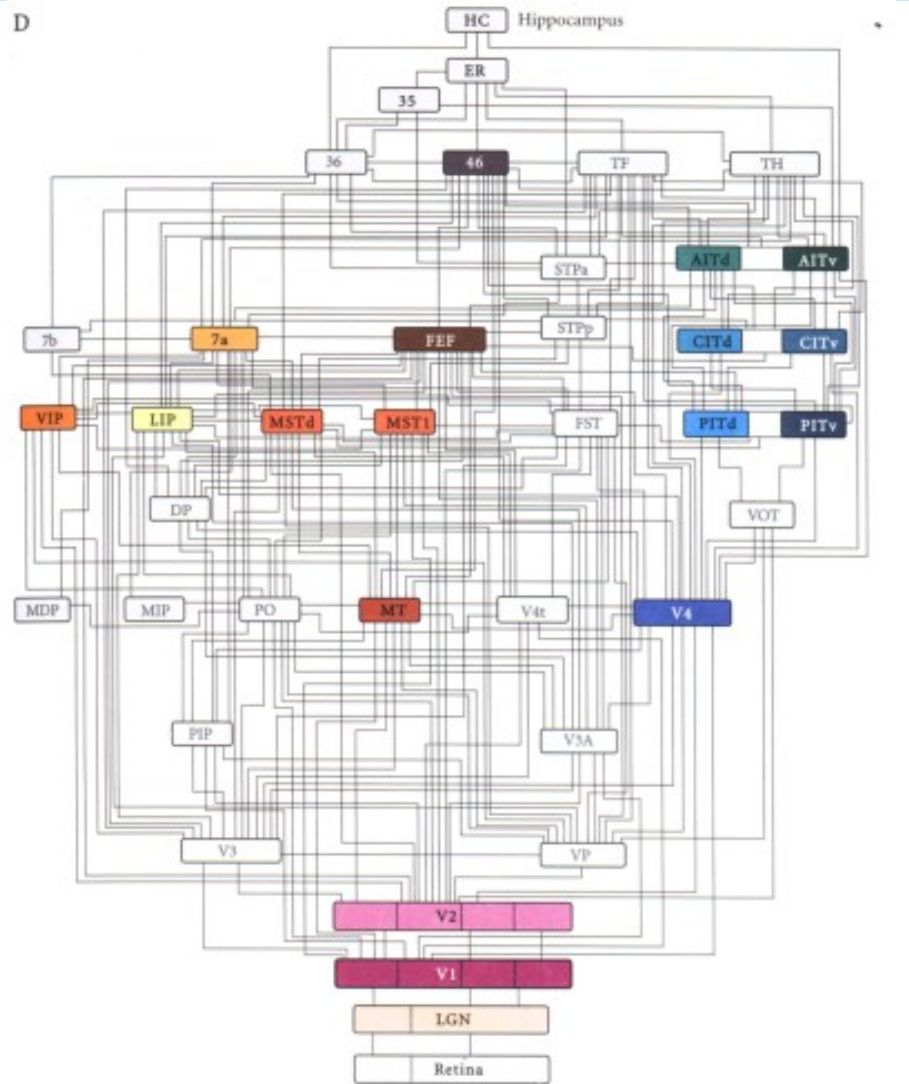
Orbito-frontal areas

(Architectonic: Ongur & Price, 2001; Gusnard et al., 2003)




Visuotopic areas

(fMRI: Hadjikhani et al. 1998; Tootell & Hadjikhani, 2001; Press et al., 2001; Van Essen, 2003)




The Human Visual System (2)

The Retina



The Human Visual System (3)

Ganglion cells are sensitive to brightness differences (Left: on-center cell, right: off-center cell)



OpenCV

- hochoptimierte, echtzeit-taugliche Basisoperationen für Computer Vision (C++ Code)
- Framegrabber für Kameras
- Implementation durchwegs schneller als Intel IPP, besonders bei multi-thread programming
- Auch für AMD Prozessoren verwendbar
- Brauchbares Lernsystem für BDTHF (V1.1.0 verwenden - V2.0 noch sehr buggy, evtl. auch V2.1..)
- Brauchbare SIFT-Implementierung (cvSURF)


OpenCV Modelle

Low-cost Eyetracking (1)

- **Problem:** Existierende Hardware-Eyetracking-Systeme sind zu teuer für große Marketing-Studien.
- **Lösung:** Low-cost Eyetracker auf der Basis von handelsüblichen USB-Kameras (Softwarelösung)

Vorteile


- Hardwarekosten ca. 60 EUR pro Eyetracking-Arbeitsplatz – ~100 Arbeitsplätze zum Preis eines existierenden Systems!
- Verwendung des eigenen PCs
- Studienteilnehmer arbeiten in gewohnter Umgebung
- Auch für integrierte Notebookkameras/Handycams



Low-cost Eyetracking (2)


Klassisches Eyetracking

- Projektion von mehreren IR-Reflektionen ins Auge (glints)
- Filterung des Kamerabildes nach Infrarot-Wellenlänge
- Sichtwinkel aus glint-Position „leicht“ berechenbar.



Low-cost Eyetracking

- Gesichtserkennung und Finden der Augen im Gesicht
- Direkte Erkennung von Iris Pupille typischerw. verdeckt
- Kopfposition/-winkel muß aufwendig kompensiert werden




Low-cost Eyetracking (3)


Video

Boosted DTs of Haar-like Features (1)


1. Edge features



2. Line features



3. Center-surround features



Vom menschlichen Sehsystem abgeleitet

- Hell/Dunkel-Unterschiede (Kontrast)
- Berechnet in allen möglichen Größen über einem Fenster fixer Größe (zB 24x24, 40x40 Pixel)
- 117,941(!) Features bei 24x24 Pixel-Fenster

Boosted DTs of Haar-like Features (2)

Trainieren

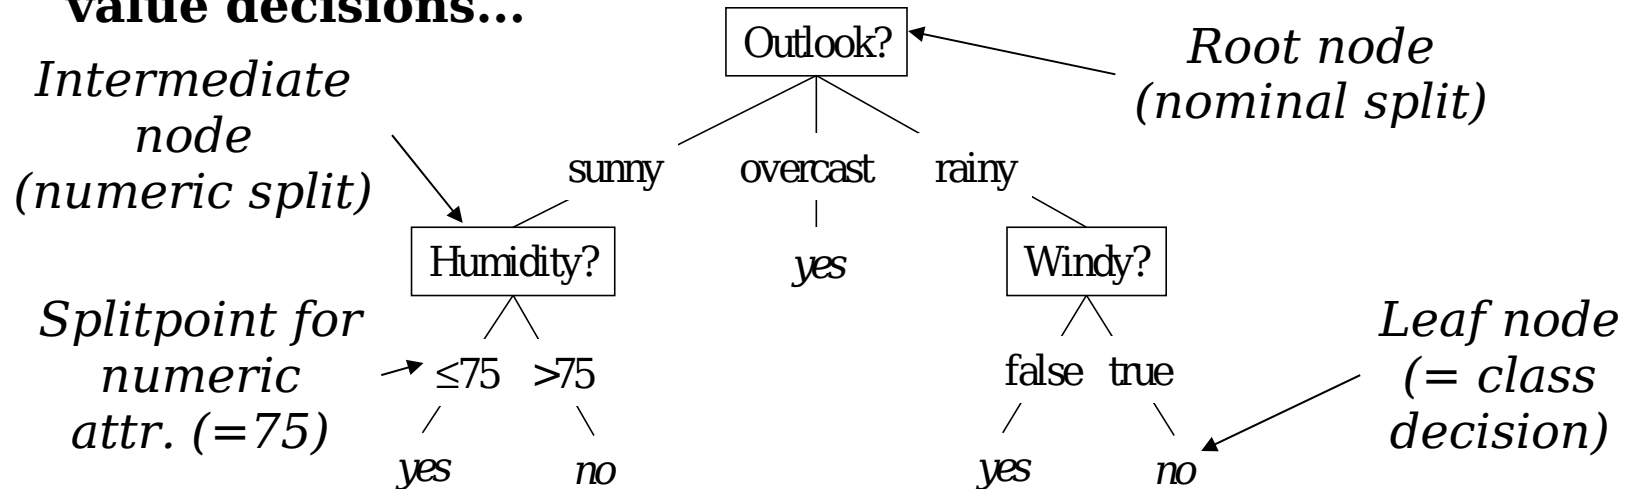
- Positive und negative Bilder (>1000 pro Klasse)
- Berechnung aller Features für alle möglichen Unterfenster im Bild
- Lernen von Decision Trees / Stumps
- „Boosting“ zur Reduktion der Fehlerrate
- Lernzeit ca. 1-4 Wochen je nach Settings

Testen

- Nur die Features, die im Decision Tree vorkommen, müssen tatsächlich berechnet werden – dadurch schnell genug für Echtzeit!
- Boosting führt trotzdem zu einem guten Modell

Boosted DTs of Haar-like Features (3)

Decision Tree: A recursive structure of attribute/class value decisions...



...which is equivalent to a set of rules, one for each path from the root node:

outlook=sunny & humidity \leq 75 \Rightarrow yes, outlook=sunny & humidity $>$ 75 \Rightarrow no, outlook=overcast \Rightarrow yes, outlook=rainy & windy=false \Rightarrow yes, outlook=rainy & windy=true \Rightarrow no

Decision Stump: Decision Tree with only one level.

Boosted DTs of Haar-like Features (4)

AdaBoost.M1:

- Apply the same learner sequentially to reweighted training sets, given more weight to examples which have been misclassified previously.
- Final classification is a weighted vote of the component learners.
- Improves dramatically on the performance of even weak base learners; reduces both bias *and* variance of base learners.

[Breiman,96]: AdaBoost + C4.5 = best off-the-shelf classifier


1. Initialize the example weights $w_i=1/N$ for $i=1,2,\dots,N$
2. For $m=1$ to M :
 - (a) Fit a classifier $f_m(\mathbf{x})$ to training data weighted with w_i
 - (b) Compute weighted error $Err_m = \sum w_i I(y_i \neq \text{sign}(f_m(\mathbf{x}_i))) / \sum w_i$
 - (c) Compute $a_m = \log((1 - Err_m) / Err_m)$
 - (d) Set new w_i to $w_i (\exp(a_m (I(y_i \neq \text{sign}(f_m(\mathbf{x}_i))))))$, $i=1,2,\dots,N$
3. Output final $f(\mathbf{x}) = \sum a_m f_m(\mathbf{x})$

Magazinerkennung

Magazinseiten-Erkennung

Problem: Erkennung von Magazin-Titel und Innenseiten via Handy- und Knopfkameras für Marktforschungszwecke

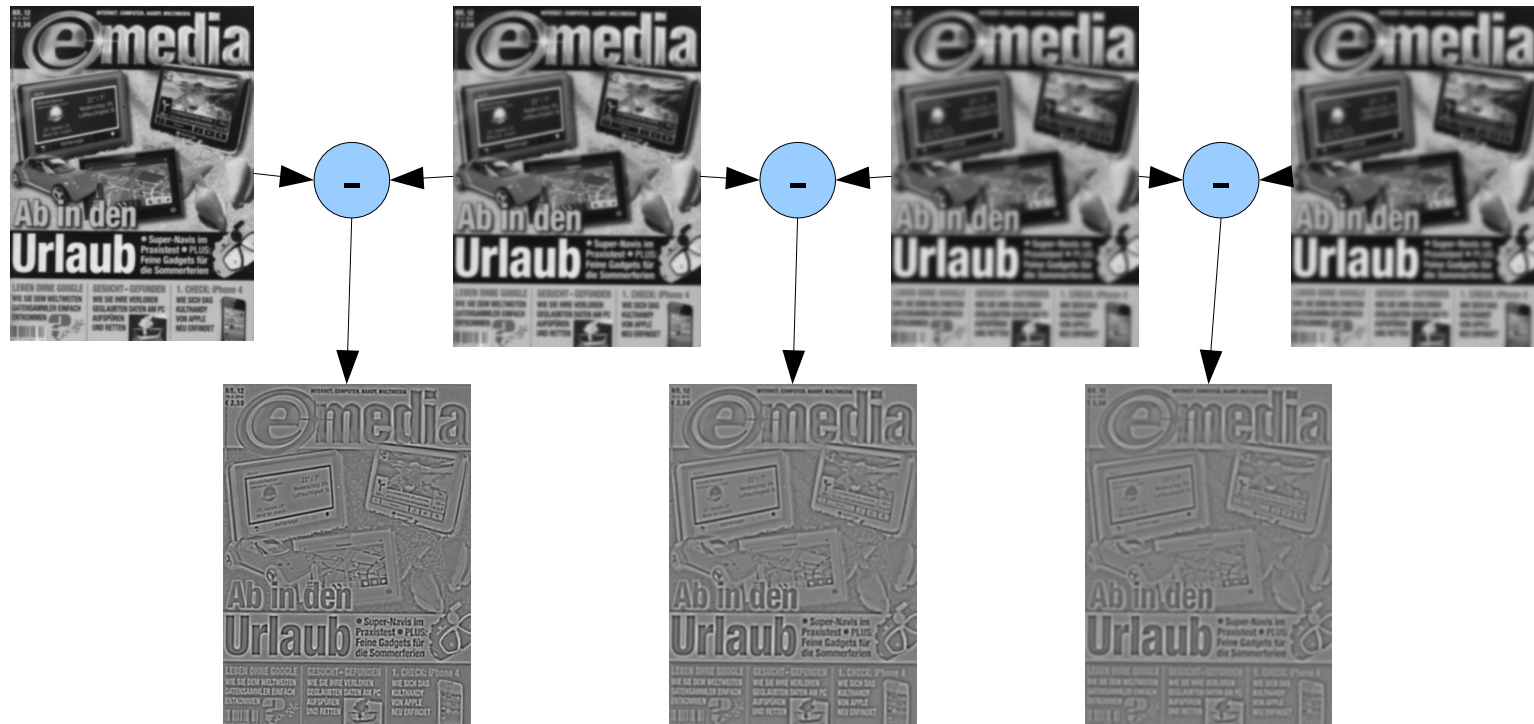
Lösung: Automatische Zuordnung via SIFT auf Basis von Referenzbildern der Magazinseiten als PDF



Scale Invariant Feature Transform (1)

[Lowe, 1999] & [Lowe, 2004]


- Scale-space extrema detection via difference-of-gaussian. Keypoint localization by local quadratic interpolation



Scale Invariant Feature Transform (2)

- Orientation assignment via direction histogram peaks. Obtain Keypoint descriptors by sampling & trilinear interpolation

Image keypoints with 128-dimensional descriptors



Scale Invariant Feature Transform (3)

Matching keypoints with an image database

- Nearest neighbors & euclidean distance
- Best-Bin-First: fast approx. of nearest-neighbor
- Least-squares solution of pose to determine final affine transform of the object for accurate localization



Algorithmen (1)

Aufbau spezifischer Objekt-Detektoren

- für dynamische & elastische Objekte: Boosted Decision Trees of Haar-like Features (BDTHL)
- für statische & starre Objekte: Scale Invariant Feature Transform (SIFT)

Algorithmen (2)

Anwendungen

- BDTHL: Erkennung komplexer, flexibler Objekte (Gesichts-, Fußgänger-, Auto-Erkennung...)
- SIFT: allgemeine Objekterkennung unabhängig von Position, Größe & Lage; Matching von ganzen Bildern; nur für starre Objekte geeignet (Gebäude, Statuen)

Testaufnahmen

deFlicker (1)

- **Problem:** Existierende Hochgeschwindigkeitskameras zeigen ein deutliches Flackern bei Nachtaufnahmen aufgrund v.Stadion-Scheinwerfern
- **Lösung:** Softwaremäßige Korrektur des Flackerns in Echtzeit für HDTV Video.



Hintergrund

- Weit verbreitete Stadion-Scheinwerfer flackern ($\sim 130\text{Hz}$)
- Nachtaufnahmen mit Hochgeschwindigkeitskameras ($>150\text{fps}$) flackern deshalb sehr stark.
- Auch LED-Werbebanner können flackern, wenn Stromversorgung nicht gut genug abgeschirmt.



Video

**Vielen Dank
für die
Aufmerksamkeit!**