



Computer Vision „Crashkurs“

BarCamp Wien, 29.05.2010



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

- Algorithmen – SIFT, BDTHF, Conv. NN
- Frameworks – OpenCV, ImageJ, WEKA
- Demos OpenCV Facedetection, Google Goggles



Anwendungen

- Magazinseiten-Erkennung (SIFT)
- Erkennung von Go-Spielpos. (SIFT/ImageJ,WEKA)
- Low-cost Eyetracking (BDTHF/OpenCV,WEKA)
- Entflickerung von Highspeed-Video (OpenCV)

The Human Visual System (1)

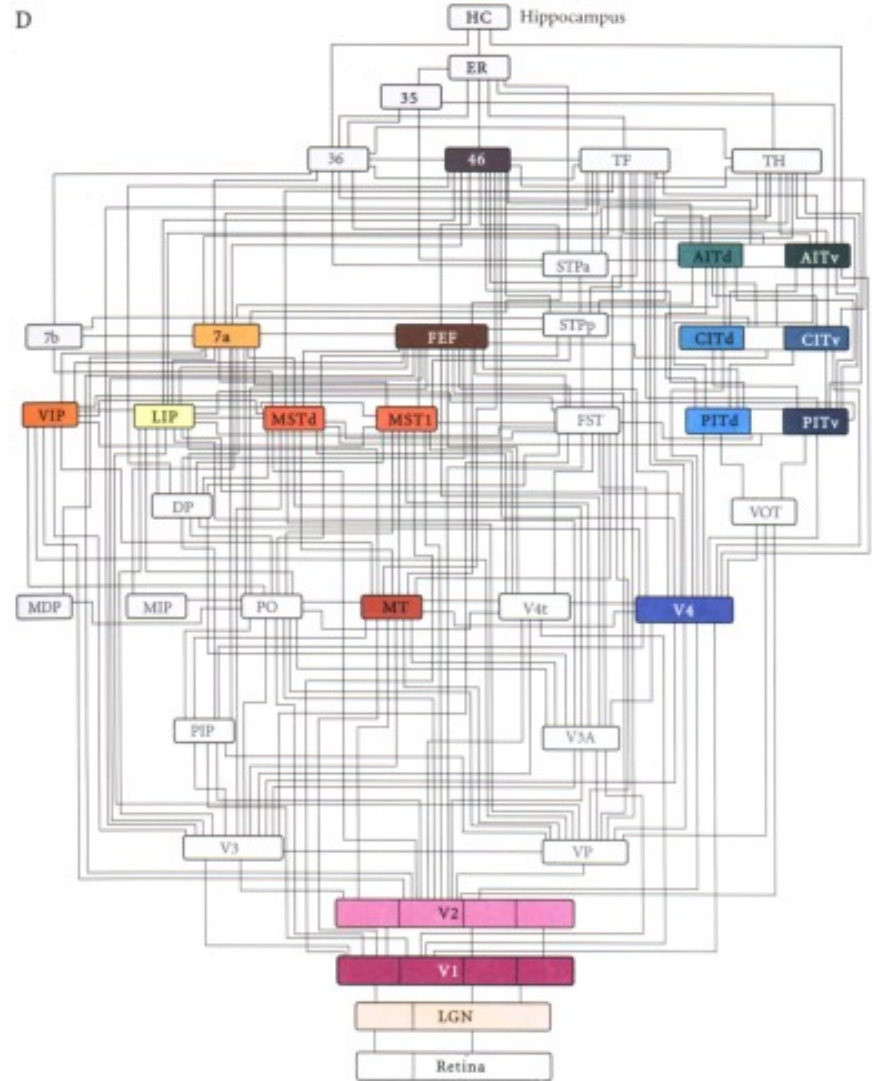
Orbito-frontal areas

(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)



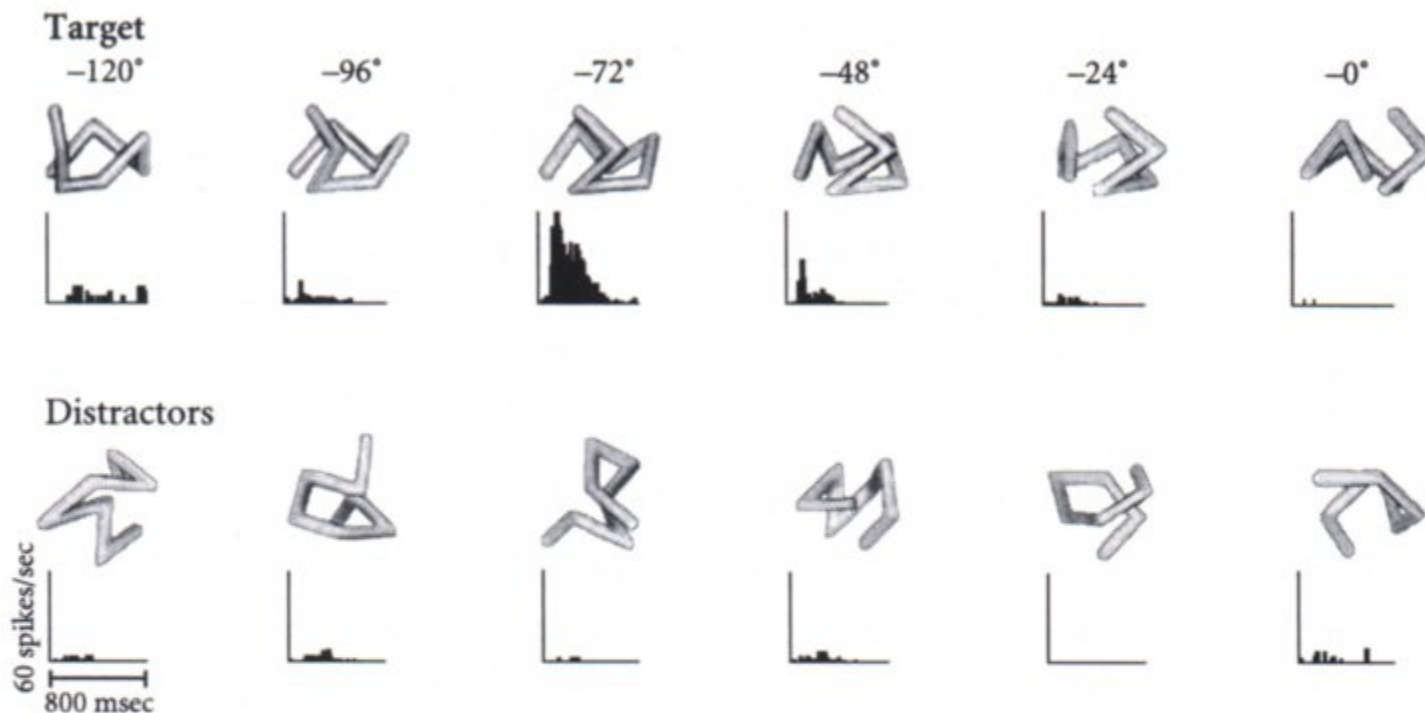
The Human Visual System (4)

Orientation columns in primary visual cortex are sensitive to image gradients in specific directions.



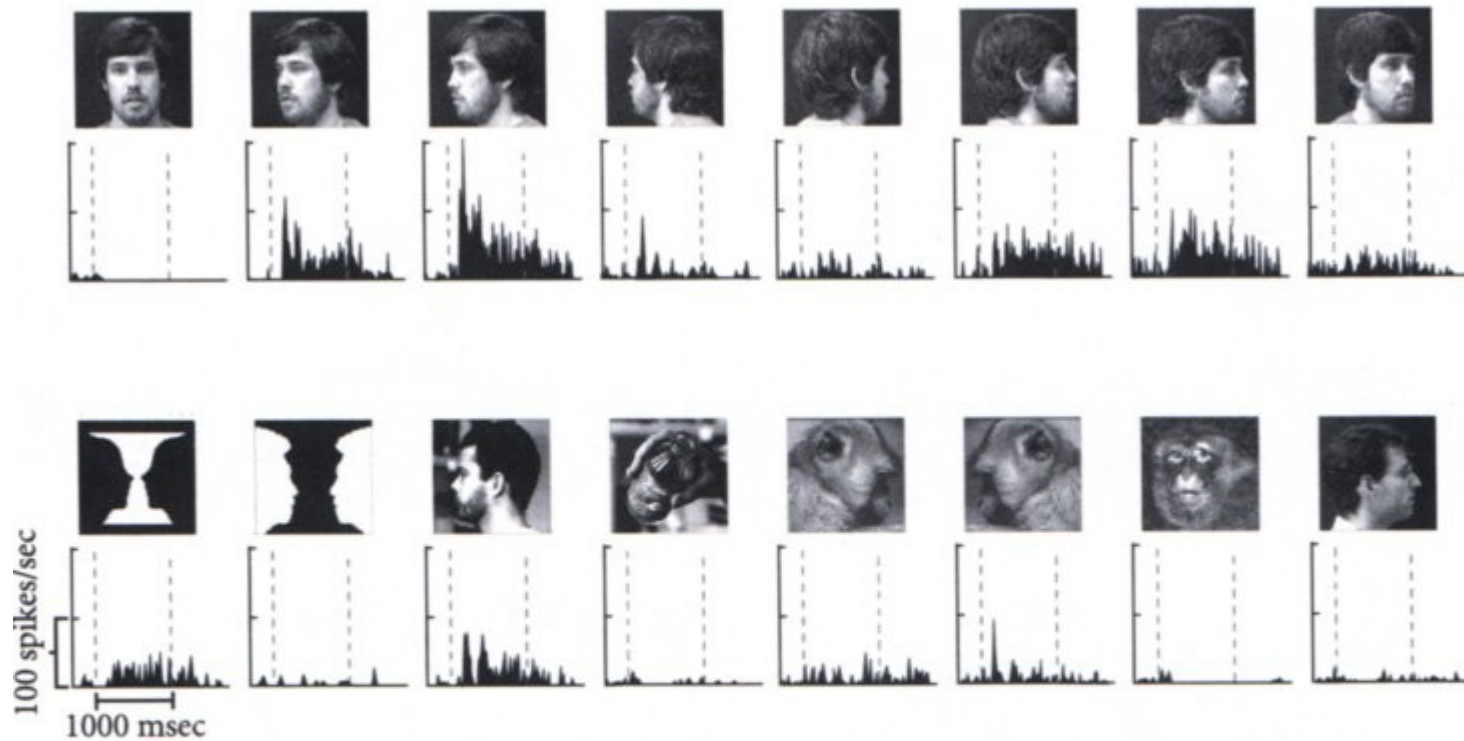
The Human Visual System (5)

Higher vision areas have more specific feature detectors. This is a paper-clip recognition neuron...



The Human Visual System (6)

... and this is a bearded-faces-in-profile neuron.



Algorithmen (1)

Aufbau spezifischer Feature-Detektoren

- für statische & starre Objekte: Scale Invariant Feature Transform (SIFT)
- für dynamische & elastische Objekte: Boosted Decision Trees of Haar-like Features (BDTHL)
- für beide Arten von Objekten: Convolutional Neural Networks (convNN)

Algorithmen (2)


Übliche Anwendungen

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

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




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

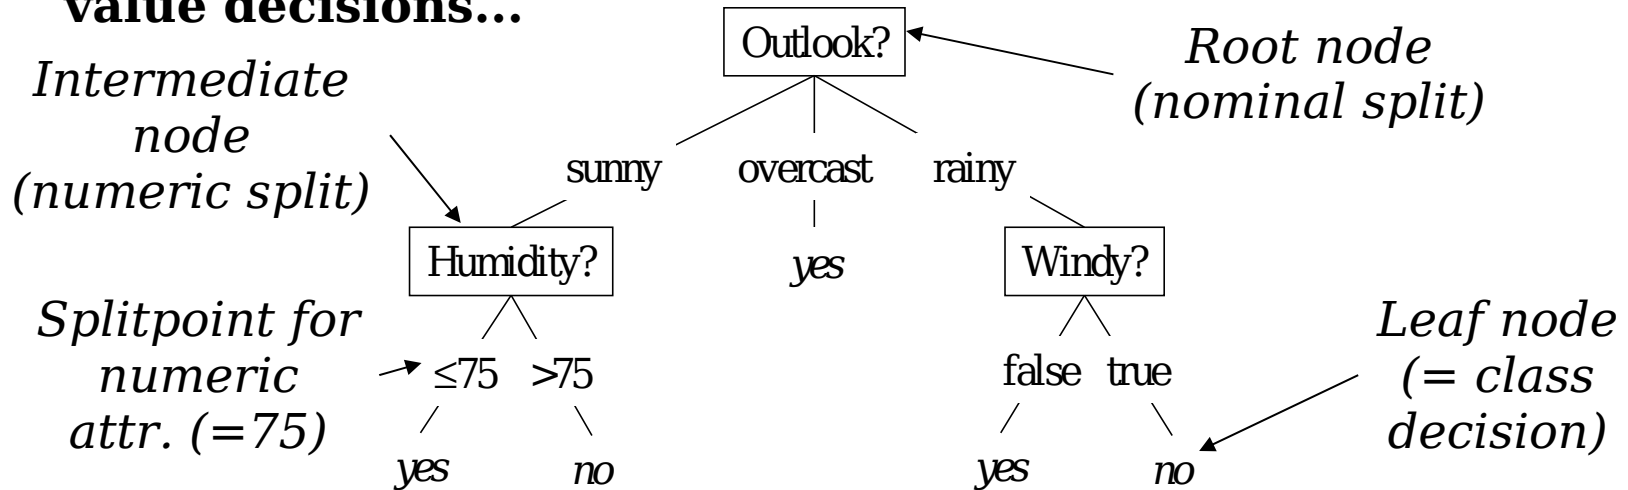
- Positive und negative Bilder (>1000 pro Klasse)
- Berechnung aller Features für alle möglichen Unterfenster im Bild
- Lernen von Decision Trees / Stumps
- Boosting zur Reduktion der Fehlerrate
- Lernzeit ca. 1-4 Wochen je nach Settings

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 $f(\mathbf{x}) = \sum a_m f_m(\mathbf{x})$


Convolutional Neural Networks (1)



Perceptron (linear binary threshold unit)

- Computes a linear function of \mathbf{x} (assume adding an $x_0=1$ to \mathbf{x} , so that constant term w_0 can be handled).
 $f(\mathbf{x}) = \text{sign}(\mathbf{x}^T \cdot \mathbf{w})$. \mathbf{w} is initialized randomly.
- *Perceptron training rule*: $\mathbf{w} \leftarrow \mathbf{w} + \eta(y - f(\mathbf{x})) \cdot \mathbf{x}^T$, where y is the true output value from training data (± 1), and η is the learning rate.
- Concept boundary is a hyperplane which separates classes $+1$ & -1 .


Convolutional Neural Networks (2)



Multi-Layer Perceptron

- Kombination vieler Perceptrons
- Lernen (=Gewichte optimieren) mit Backpropagation
- Explizite Bias-Knoten mit konstantem Outputwert
- Kann auch nichtlineare Konzepte (wie XOR) lernen

Convolutional Neural Networks (3)



Convolutional Neural Network

- Subsampling: Mittelwert von benachbarten Pixeln
- Convolution: Inputs = benachbarte Pixels, Gewichte für alle Knoten gleich (weight sharing)
- Lernen mit adaptierter Backpropagation
- Sehr instabiler Lernalgorithmus, Performance hängt stark von Netzwerkstruktur ab
- Kaum Open Source Code fürs Training verfügbar

Frameworks (1)

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 geeignet
- Brauchbares Lernsystem für BDTHF (V1.1.0 verwenden - V2.0 noch sehr buggy...)
- Apropos: Etliche lästige Bugs! (ellipse fitting, SVD)

Frameworks (2)

ImageJ

- Optimierte Java-Implementierung von Basis- und erweiterten Computer Vision Operatoren
- Implementation typischerweise langsamer als OpenCV, dafür praktisch keine Bugs.
- Größere Auswahl von CV-Algorithmen.
- Für Nicht-Echtzeit-Prototypen gut geeignet
- Gut geeignet zur Integration mit WEKA

Frameworks (3)

Waikato Environment for Knowledge Analysis

Die weitverbreiteste Data Mining Suite, für Anwendung, Lehre und Forschung

<http://www.cs.waikato.ac.nz/~ml/weka>

- Stabilität, Verfügbarkeit und Qualität der Lernalgorithmen noch immer weit jenseits von kommerziell verfügbaren Tools.
- 1000+ Contributors seit 1999, GPL, vielfach ausgezeichnet (InfoWorld 2007)
- Benannt nach einem neugierigen flügellosen Vogel, der in Neuseeland heimisch ist und unter Naturschutz steht



OpenCV Facedetection

Google Googles

Demos (2)

OpenCV Facedetection

- Genauigkeit (Precision) relativ gut
- viele False Positives bei komplexen Hintergründen


Google Goggles

- hauptsächlich SIFT (Buch-Covers, Sehenswürdigkeiten, allgemeine Objekte, ...)
- OCR als Fallback-Option, dann Google-Suche
- integrierter Barcode-Leser eher trivial


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



Erkennung von Go-Spielpositionen



Problem: Go-Spieler haben keine Zeit, die eigenen Spiele mitzuschreiben.

Lösung: Automatische laufende Erkennung der Spielposition über Handy-Bilder.

- Pro Einzelbild 98.4% genau. 4/6 Schritte verwenden WEKA & Image] [Seewald, 2010]


Figure 1: Steps 1-6 with sample images after each step, left-to-right, top-to-bottom.

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)

Vorgehensweise

- OpenCV: Echtzeitverarbeitung & Gesichtserkennung
- Training Augenerkennung: pixelbasierte Features mit WEKA trainiert (Sclera, Iris/Pupille, Haut) und endgültiges Modell nach C konvertiert (toSource())



Low-cost Eyetracking (4)

Video

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.



deFlicker (2)

Entwicklung eines Prototypen

- Entfernung des Flackerns in Echtzeit für HDTV Input/Output Video (720p / 50-60Hz, 1080i / 50Hz)
- Leistungsfähiger Rechner notwendig (~8 Kerne)
- Bis jetzt eingesetzt bei UEFA Testspielen, Olympia 2010 (Vancouver) und zahlreichen kleineren Events.
- Kürzlich ausgestellt bei NAB Show 2010 (Las Vegas)

- OpenCV: Echtzeitverarbeitung
- Dedizierte Karte für HDTV input/output via DMA
- Linux pthread library & Semaphores
- Läuft auf 64bit Linux

Video

Vielen Dank für die Aufmerksamkeit!

**Für Fragen stehe ich jederzeit
gerne zu Ihrer Verfügung.**