

Gaze Tracking

Dennis Müller & Sergej Bomke

Hochschule RheinMain

February 24, 2017

Gliederung

1 Datenquellen

2 CNN


3 SVR

4 Evaluation

Datenquellen

MPIIGaze


- 213.659 Bilder von 15 Personen
- Breites Spektrum an Aufnahmeorten, Zeit und Beleuchtung
- Bilder sind normalisiert für rechtes und linkes Auge
- 3D Kopfhaltung und 3D Blickrichtung



Mit WebCam aufgenommene Bilder

- MPIIGaze kompatibel


Vorverarbeitung von Bilder



Head Pose Estimation

Perspective-n-Point (PnP) Problem:

- $s \ m' = A[R|t]M'$
- 3D Punkte p_i in Weltkoordinatensystem
- 2D-Projektionen u_i im Bild
- Ziel: Pose (R, t) der Kamera zu ermitteln





Quelle: OpenCV Tutorials, <http://docs.opencv.org> (abgerufen am 22.02.2017)

Head Pose Estimation

- OpenCV bietet verschiedene Ansätze zur Lösung des PnP-Problems
- 3D Punkte: generisches Gesichtsmodell aus MPIIGaze
 - Positionen von sechs Landmarks
 - Aufgenommen mit einer externen Stereo-Kamera
 - Mittelwert über alle Teilnehmer
- 2D-Koordinaten: Landmarks
 - Ermittelt mit Dlib Framework
- Parameter der Kamera
 - Kamerakalibrierung mit dem Schachbrett


Head Pose Estimation

- Ermittelter Wert ist instabil
 - Filterung der Landmarks
 - Diverse Gesichtsmodelle
- Lösung
 - Feste Kopforientierung



Normalisierung

- Skalierung und Drehung
 - `cv2.getPerspectiveTransform`: Berechnet die Matrix einer 3x3 perspektivischen Transformation
 - `cv2.warpPerspective`: Wendet eine perspektivische Transformation auf ein Bild an
- Beschneiden auf 60x36 Bilder
- Histogram equalization



Architektur CNN

Entnommen aus Vorlage-Paper




Figure 1: Kernarchitektur des CNNs

Lernen

Lernen auf rechtem Auge von MPIIGaze-Datensatz

Lernrate = 0.0001

Für Demo: 177847 Trainingsbilder, 280 Testbilder

Für Evaluation: 177458, 669 Testbilder

Loss-Funktion: L2-Loss

Hürdenübersicht

- Learning Rate ermitteln
- Inkonsistenzen in Vorlage: Loss- und Accuracy-Funktion
- Loss-Funktionen
- Probleme in MPIIGaze
- Sterbende Neuronen bei Versuch, das Problem runter zu skalieren
- Generalisierungsprobleme

Schwierigkeiten

In Vorlage wurde eine Learning Rate von 0.1 verwendet → Hat in Tensorflow nicht funktioniert

Vorlage benutzt Caffe mit modifizierten "Euclidian Loss" und "Accuracy"; beides der Winkel zwischen den rekonstruierten Vektoren (Prediction vs. Ground Truth)
→ Kann NaN sein, und Paper spricht von L2-Loss

Verschiedene Loss-Funktionen im Verlaufe des Projektes ausgetestet bei Lernproblemen, aber bei L2-Loss verblieben

MPIIGaze

Beinhaltet unterschiedliche Ground Truth-Daten für linkes und rechtes Auge → Datensatz könnte schwierig ausfallen

Schwere Outlier in Daten der 4.ten von 14 Personen:



Figure 2: "Normalisiertes" Bild

Reduktion auf Bilder

Versuch, Netzwerk nur mit Bildern zu füttern...

- Extraktion von Daten aus MPIIGaze mit Kopfwinkel nahe 0
→ Nur noch ~150 Bilder
- Training mit ganzen Daten → Funktioniert nicht, Neuronen in Convolution sterben

Generalisierung

Netzwerk fitted recht gut auf Trainingsdaten, aber nicht auf Testdaten.




Figure 3: Trainingsphase auf MPIIGaze: Batch vs. Testdaten, Winkelabweichung zwischen Vektoren

Test= 16.83364486694336° , Training= 5.811657905578613°

Generalisierung

Diverse Versuche, bei Generalisierung zu helfen:

- Dropout auf beiden Fully-Connected-Layers: Bremst nur Fitting auf Trainingsdaten aus
- L1-Regulation auf Convolution-Filter: Kein Effekt
- L2-Regulation auf Gewichte der FCLs: Moderate Angleichung von Test- und Trainingsdaten

Keine weiteren Versuche aufgrund von Zeitlimits, aber Anzahl der versteckten Neuronen ist auch noch ein möglicher Parameter.


Support Vector Regression

- `sklearn.svm.SVR`
 - RBF-Kernel
 - Keine native Unterstützung von Multi-Target-Regression
- `sklearn.multioutput.MultiOutputRegressor`
 - Ein Regressor per Target
 - Trainieren kann parallelisiert werden
 - Nicht möglich verschiedene Parameter zu übergeben

Support Vector Regression

Freie Parameter:


- C
- γ



Quelle: Scikit-Learn, <http://scikit-learn.org> (abgerufen am 22.02.2017)

Parameterbestimmung mit GridSearch

- 3-fache Kreuzvalidierung
- 49 candidates
 - 147 Fits
- R^2 Score



Features

Raw-Bilder:

- 2.160 Features

HOG:

- Signed gradients, 2x2 Cells per Block und 6x4 Blocks
- 2.772 Features



Multiple HOG

- 2x2 Cells per Block, 1x2, 3x1, 3x2, 6x4 Blocks
- 3.600 Features

Features

PCA:

- Reduktion auf 256 Features
- Hohe Speicherverbrauch beim fit()

+ Head Pose (yaw und pitch)


- Problem: Bild-Features dominieren
- Lösung: $HeadPose = HeadPose * \frac{AnzahlFeatures}{2} * \alpha$

Featuresbestimmung mit Crossvalidierung:


- HOG + PCA
- $\alpha = 0.25$

CNN vs SVR

- Trainingsdaten:
 - 177.913 MPIIGaze
 - 5.880 Kalibrierungsbilder + 6.000 MPIIGaze
- Testdaten:
 - 670 MPIIGaze
 - 1176 Kalibrierungsbilder



CNN vs SVR



CNN vs SVR

