

# Robotik I – Bildverarbeitung in der Robotik

Tamim Asfour


KIT-Fakultät für Informatik, Institut für Anthropomatik und Robotik (IAR)  
Hochperformante Humanoide Technologien (H<sup>2</sup>T)



# Bildverstehen







**Was wir sehen!**



**Was ein Roboter sieht!**




# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- Punktwolken
- SLAM
- Anwendungsbeispiel



# Literatur

- Multiple view geometry in computer vision
  - R. Hartley und A. Zisserman
  
- Digital Image Processing
  - Rafael C. Gonzalez and Richard E. Woods
  
- Automatische Sichtprüfung
  - J. Beyerer, F. Puento León und C. Frese
  
- Computer Vision – Das Praxisbuch
  - Pedram Azad, Tilo Gockel und Rüdiger Dillmann



# Programmbibliotheken

## ■ OpenCV

- <http://opencv.org>
- Facedetection, Optical Flow, GPU Computing




## ■ Point Cloud library (PCL)

- <http://pointclouds.org>
- Pointcloud processing, RANSAC primitive fitting, ICP



## ■ Integrating Vision Toolkit (IVT)

- <http://ivt.sourceforge.net>
- Image processing, Feature matching



# Motivation

## Was ist das Problem?

- Wie können wir einem Roboter „Sehen“ ermöglichen?

## Warum ist *Computer Vision* schwer?

- Computer Vision ist nicht nur Bildübertragung von Kamera auf den Computer sondern auch deren **Verarbeitung** und **Interpretation**
- Bei der Übertragung (3D Welt → 2D Bild) geht eine Dimension verloren

## Unterschiedliche Aspekte

- **Photometrie:** Wahrnehmung abhängig von Beleuchtung und Materialeigenschaften
- **Dynamik:** Bewegung in der Szene bzw. in der Kamera
- **Okklusion:** Ein Objekt kann z.B. nicht vollständig sichtbar sein
- Interpretation Abhängig von der aktuellen Aufgabe

# Motivation

- Das Sehvermögen ermöglicht die Wahrnehmung der Umwelt
- Nutzbarkeit in einem technischen System
  - Visuellen Informationen müssen aufgenommen werden
    - gute Qualität
    - digitales Format
  - Relevante Informationen müssen aus den Daten extrahiert werden
- **Bilderfassung:** Hardware
- **Bildverarbeitung:** überwiegend Software





# Lena-Bild

Das ursprüngliche Lena-Bild stammt aus der US-amerikanischen November-Ausgabe des Playboy-Magazins des Jahres 1972.

Es zeigt das schwedische Playmate **Lena Söderberg** (vom Playboy „Lenna Sjööblom“ genannt).



[https://de.wikipedia.org/wiki/Lena\\_\(Testbild\)](https://de.wikipedia.org/wiki/Lena_(Testbild))



# Kamerabeispiele



PointGrey Flea3 USB3



CMU MultiSense S7



Karlsruhe Humanoid Head



Intel RealSense R200



Roboception rc visard

# MultiSense S7 and S7S



<https://www.youtube.com/watch?v=75A8iFeVgh8>




# Roboception: rc visard 65 - Bin picking application



<https://www.youtube.com/watch?v=-leZbn1aA8Q>

# Inhalt

- **Bildrepräsentation**
- Kameramodell
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- Punktwolken
- SLAM
- Anwendungsbeispiel



# Bildrepräsentation


- Bilder müssen im Computer/Roboter repräsentiert werden
- Ein Bild ist ein 2D Gitter von diskreten Punkten (**Pixel**)
- **Bildkoordinaten** (hier):
  - $u$  (horizontal)
  - $v$  (vertikal)
  - Ursprung ist oben links
  - Einheiten: Pixel
- Die **Farbe** eines Bildpunktes kann auf unterschiedliche Weise repräsentiert werden
- **Graustufenbilder**: Für jeden Pixel wird ein Helligkeitswert abgelegt
  - Normalerweise **ein Byte** pro Pixel, i.A. Werte in  $[0, 255]$

# Bildrepräsentation - Monochrombild

**Monochrombild:** Diskrete Funktion

$$Img: [0 \cdots n - 1] \times [0 \cdots m - 1] \rightarrow [0 \cdots q]$$

$$(u, v) \mapsto Img(u, v)$$



0 für schwarz  
255 für weiß

Üblich:

$$q = 255$$

$$n = 640, \quad m = 480 \text{ (VGA)}$$

oder  $n = 1920, \quad m = 1080 \text{ (1080p „Full HD“)}$

$$n = 3840, \quad m = 2160 \text{ (2160p „Ultra HD“ oder 4K UHD)}$$

# Datenmenge

- Schwarz/Weiss mit 30 Hz, 640x480 Pixel und 1 Byte pro Pixel

$$30\text{Hz} * 640 * 480 * 1\text{Byte} \approx 8.79 \text{ MB/s}$$

- Farbbilder mit 30 Hz, 640x480 Pixel und 3 Byte pro Pixel

$$30\text{Hz} * 640 * 480 * 3\text{Byte} \approx 26.37 \text{ MB/s}$$




# Bildrepräsentation - Auflösung

- Die Abtastung ist der Hauptfaktor, der die räumliche Auflösung eines Bildes bestimmt.
- Die Auflösung ist das kleinste erkennbare Detail in einem Bild.



# Bildrepräsentation - Auflösung II



- Wenn man die Anzahl der Graustufen konstant hält und die räumliche Auflösung verringert, ergibt sich ein Schachbretteffekt!

# Bildrepräsentation - Farbbild

## Farbbild:

- Verschiedene Farbmodelle für unterschiedliche Anwendungen
- Klassifikation nach erreichbarem Farbraum

## Beispiele:

- *RGB*-Modell (Rot-Grün-Blau-Modell): speziell für Monitore (Phosphor-Kristalle)

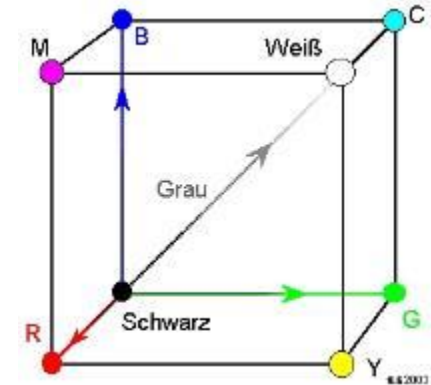
$$\text{Img}(u, v) = (r, g, b)^T \in \mathbb{R}^3$$

- *HSI* (Hue, Saturation, Intensity): geeignet für Farbsegmentierung
- *CIE*: physikalisch (Wellenlänge)
- *CMYK*-Modell (Cyan, Magenta, Yellow, Schwarzanteil „Key“): Farbdrucker (subtraktive Farbmischung)
- *YIQ*: Analoges Fernsehermodell

# Bildrepräsentation – RGB Farbraum

## RGB Farbraum

- Additive Farbmischung
- Drei Farbwerte: *Rot*, *Grün*, *Blau*
- RGB24
  - Ein Pixel wird durch **3 Bytes** repräsentiert (rot, grün, blau)
  - Jedes Byte entspricht 8 Bits  
→ 256 Abstufungen für jeden Farbwert
  - $2^8 \times 2^8 \times 2^8 = 16,8$  Mio. Farben darstellbar



24-Bit RGB Farbwürfel

$$Img: [0 \dots n-1] \times [0 \dots m-1] \rightarrow [0 \dots R] \times [0 \dots G] \times [0 \dots B]$$

$$(u, v) \mapsto Img(u, v) = (r, g, b)^T$$

# Bildrepräsentation – HSI Farbraum

## HSI (HSV) Farbraum


- Hue (Farbnuance), Saturation (Sättigung), Intensity/Value (Lichtintensität/Helligkeit)
- Kodiert der Farbinformation **getrennt** von Helligkeit und Sättigung der Farbe
  - ⇒ unempfindlich gegen Beleuchtungsänderungen
- Umrechnung von *RGB* nach *HSI*
  - *H* undefiniert, falls  $R = G = B$
  - *S* undefiniert, falls  $R = G = B = 0$

$$H = \begin{cases} \theta, & \text{falls } B < G \\ 360 - \theta, & \text{sonst} \end{cases}$$

$$\theta = \arccos \frac{2R - G - B}{2\sqrt{(R - G)^2 + (R - B)(G - B)}}$$


$$S = 1 - \frac{3}{R + G + B} \min(R, G, B)$$

$$I = \frac{1}{3}(R + G + B) \quad V = \max(R, G, B)$$




# Bildrepräsentation – HSI nach RGB

Wie bestimmt man *HSI* Werte in einem *RGB* Würfel?



- Im *RGB* Format entspricht die **Helligkeitsachse** (*Intensity*) der Linie durch die Ecken Schwarz (0,0,0) und Weiß (1,1,1)!
- Die **Sättigung** (*Saturation*) eines Farbpunkts auf der Sättigungachse ist Null und erhöht sich mit dem Abstand zur Helligkeitsachse.
- Jeder Punkt im Dreieck hat die selbe **Farbnuance** (*Hue*) aber unterschiedliche Helligkeits- und Sättigungswerte, da die Schwarz und Weiß-Komponente nicht die Farbnuance ändert. Die Farbnuance wird geändert indem das Dreieck um die Helligkeitsachse rotiert wird.

# Bildrepräsentation - Unterschiede



- Die **Hauptunterschiede** im Vergleich zu dem *RGB* Modell: Das *HSV*-Farbmodell **entkoppelt Farbwerte** von den **Helligkeitswerten** und erlaubt **unabhängige** Änderung von Farbnuance-, Sättigung- und Helligkeitswerten!



# Robotik I – Bildverarbeitung in der Robotik

Fabian Paus, Tamim Asfour

KIT-Fakultät für Informatik, Institut für Anthropomatik und Robotik (IAR)  
Hochperformante Humanoide Technologien (H<sup>2</sup>T)



# Bildrepräsentation

Repräsentation eines 8-Bit Graustufen-Bildes im Speicher


- Pixel werden zeilenweise, linear abgelegt
  - von oben links nach unten rechts
  - Achtung: z.B. bei Bitmaps von unten links nach oben rechts
- Graustufen-Kodierung:
  - Ein Byte pro Pixel
  - 0 schwarz, 255 weiß, dazwischen Graustufen



# Bildrepräsentation

Repräsentation eines *RGB24* Farbbildes im Speicher


- Pixel werden zeilenweise, wie beim Graustufen-Bild, abgelegt
- Farbkodierung:
  - Drei Bytes pro Pixel
  - Für jeden Kanal gilt:
    - 0 minimale, 255 maximale Intensität




## Beispiel: Bildrepräsentation bei rc visard 160

- Roboception Kamera (rc visard 160): Stereo-Kamera System mit *160 mm* Baseline (Abstand der beiden Kameras)
- **Kamerabilder:** Bildauflösung 1280 x 960 Pixel (1.3 MPixel).
- **Tiefenbild:** Distanz der Umgebung wird aus dem linken und rechten Kamerabild relativ zum Sensor berechnet (Stereovision, später)
- **Konfidenzbild:** Abschätzung für das *Vertrauen* in die Messwerte des Tiefenbilds.

Konfidenzbild



Tiefenbild






Linke Kamera



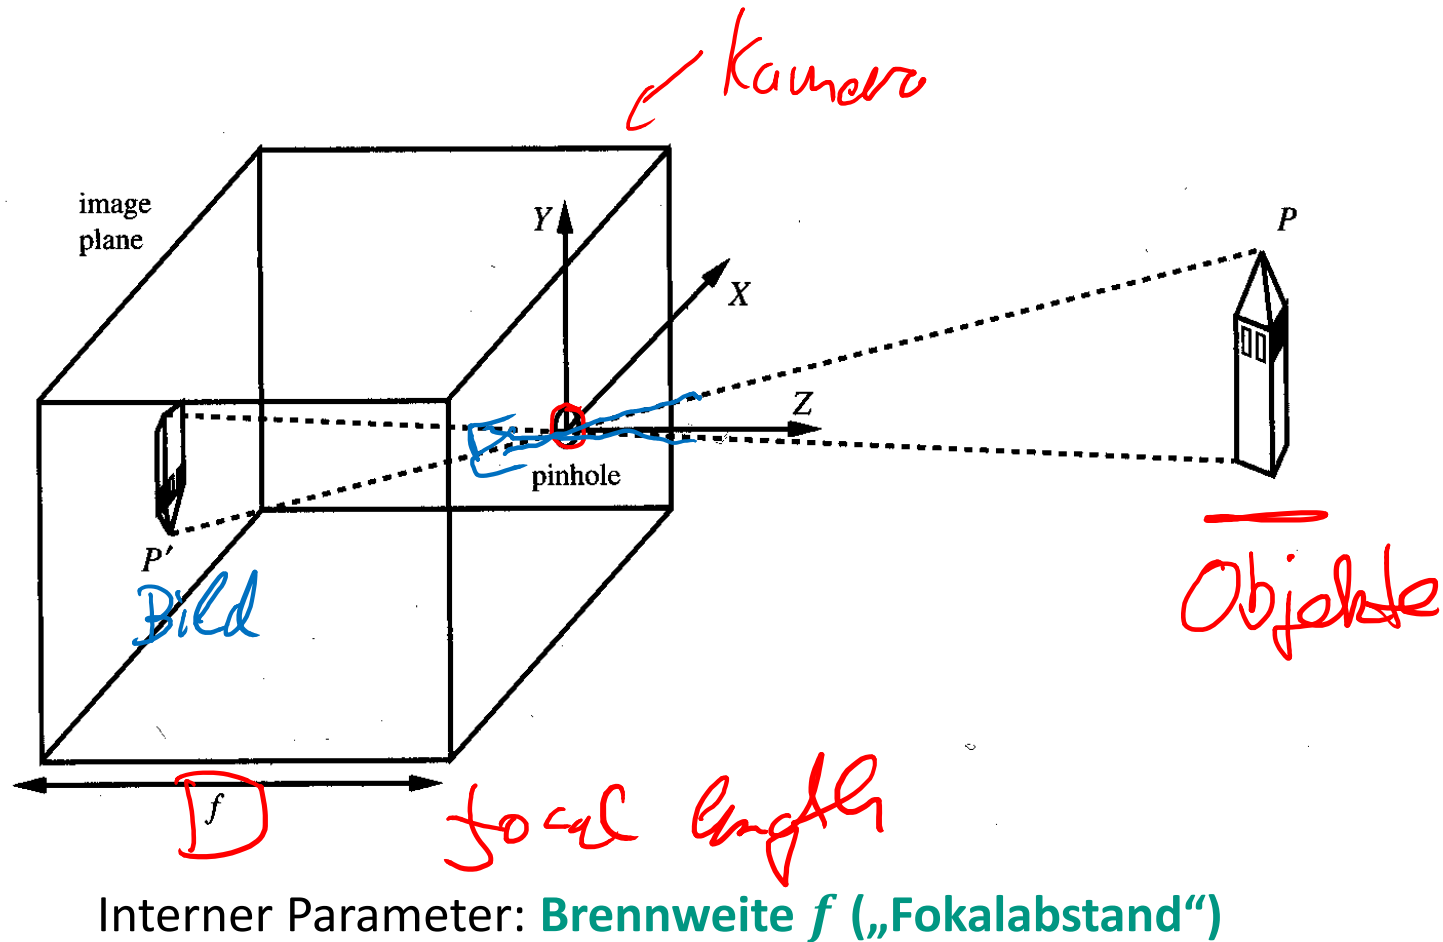
# Inhalt

- Bildrepräsentation
- **Kameramodell**
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- Punktwolken
- SLAM
- Anwendungsbeispiel



# Bildgenerierung: Lochkamera


## ■ Einfachstes Modell: Lochkamera-Modell



# Bildgenerierung: Klassisches Lochkamera Modell

## ■ Klassisches Lochkamera-Modell


- **Projektionszentrum liegt vor der Bildebene (a)**, also zwischen Szene und Bildebene
- Dadurch: Horizontal und vertikal gespiegelte Abbild






# Bildgenerierung: Lochkamera in Positivlage

- Oft verwendete Variante: Lochkameramodell in Positivlage
  - Projektionszentrum liegt hinter der Bildebene (b)
  - Dadurch: keine Spiegelung



# Koordinatensysteme

- **Hauptachse** (*principal axis*): Gerade durch das Projektionszentrum, rechtwinklig zur Bildebene
- **Hauptpunkt** (*principal point*): Schnitt der Hauptachse mit der Bildebene
- **Bildkoordinaten**: 2D-Koordinaten  $(u, v)$  eines Punktes im Bild. Einheit: Pixel
- **Kamerakoordinatensystem**: 3D-Koordinaten  $(x, y, z)$  eines Punktes relativ zur Kamera. Der Ursprung liegt im Projektionszentrum, die  $x$ - und  $y$ -Achse ist parallel zur  $u$ - bzw.  $v$ -Achse in der Bildebene. Hier Einheit: mm
- **Weltkoordinatensystem**: 3D-Basiskoordinatensystem in der Welt. Einheit in dieser Vorlesung: mm



# Bildgenerierung: Lochkamera-Projektion


Zweiter Strahlensatz zur Projektion eines Szenenpunktes  $(x, y, z)$  auf einen Bildpunkt  $(u, v)$ :

$$\begin{pmatrix} u \\ v \end{pmatrix} = \frac{f}{z} \begin{pmatrix} x \\ y \end{pmatrix}$$

*ähnliche Dreiecke*

$$\frac{x}{z} = \frac{u}{f} \quad | \cdot f$$


Bei der Projektion geht die z-Komponente verloren!



Rückprojektion:

$$\begin{pmatrix} x \\ y \end{pmatrix} = \frac{z}{f} \begin{pmatrix} u \\ v \end{pmatrix}$$

*Tiefeninfo*



# Kameraparameter

- Parameter, die das Kameramodell vollständig beschreiben
- Man unterscheidet zwischen **intrinsischen** und **extrinsischen** Kameraparameter
  - **Intrinsische Parameter:** Sie sind kameraspezifisch; unabhängig von der Auswahl des Weltkoordinatensystems. Sie bleiben konstant bei Veränderung des Aufbaus
  - **Extrinsische Parameter:** Modellieren die Transformation von Weltkoordinatensystem in das Kamerakoordinatensystem. Sie sind bei einer neuen Lage der Kamera neu zu bestimmen.
- Bisher:
  - Im Lochkameramodel nur ein intrinsischer Kameraparameter ( $f$ )
  - Kein Weltkoordinatensystem berücksichtigt, deshalb keine extrinsischen Parameter
  - Annahmen: Hauptpunkt im Ursprung des Bildkoordinatensystem; Pixel sind exakt quadratisch; Keine Linsenverzerrung.

# Erweitertes Kameramodell

- Bisheriges Klassisches Lochkameramodel ist zu einfach für Anwendungen
- Erweiterung des Modells
  - **Unabhängige Brennweiten  $f_x$  and  $f_y$**  in  $u$  und  $v$  Richtung (rechteckige Pixel)

$$f = \begin{pmatrix} f_x \\ f_y \end{pmatrix}$$

- Hauptpunkt  $(c_x, c_y)$ , ist nicht identisch mit dem Ursprung des Kamerakoordinatensystems
- Projektion von Kamera zu Bildkoordinaten kann nun erweitert werden zu:

$$\begin{pmatrix} u \\ v \end{pmatrix} = \begin{pmatrix} c_x \\ c_y \end{pmatrix} + \frac{1}{z} \begin{pmatrix} f_x \cdot x \\ f_y \cdot y \end{pmatrix}$$

$\begin{pmatrix} u \\ v \end{pmatrix} \neq K \cdot \begin{pmatrix} x \\ y \\ z \end{pmatrix}$

Ausgabe  $\uparrow$  Matrix  $\cdot$  Eingabe

- *Vorher:* Einfaches Lochkamera-Modell:

$$\begin{pmatrix} u \\ v \end{pmatrix} = \frac{f}{z} \begin{pmatrix} x \\ y \end{pmatrix}$$

# Erweitertes Kameramodell

- Unter Verwendung homogener Koordinaten kann dies in Form einer Matrixmultiplikation geschrieben werden:

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} c_x \\ c_y \end{pmatrix} + \frac{1}{z} \begin{pmatrix} f_x \cdot x \\ f_y \cdot y \end{pmatrix}$$

$$\mathbb{R}^{4 \times 4} \begin{pmatrix} x \\ y \\ z \\ 1 \end{pmatrix}$$

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} \frac{f_x}{z} & 0 & \frac{c_x}{z} \\ 0 & \frac{f_y}{z} & \frac{c_y}{z} \\ 0 & 0 & \frac{1}{z} \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix}$$

# Erweitertes Kameramodell

- Unter Verwendung homogener Koordinaten kann dies in Form einer Matrixmultiplikation geschrieben werden:

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} \frac{f_x}{z} & 0 & \frac{c_x}{z} \\ 0 & \frac{f_y}{z} & \frac{c_y}{z} \\ 0 & 0 & \frac{1}{z} \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix} \rightarrow \begin{pmatrix} u \cdot z \\ v \cdot z \\ z \end{pmatrix} = \underbrace{\begin{pmatrix} \underline{f_x} & 0 & \underline{c_x} \\ 0 & \underline{f_y} & \underline{c_y} \\ 0 & 0 & 1 \end{pmatrix}}_K \begin{pmatrix} x \\ y \\ z \end{pmatrix}$$

The diagram illustrates the conversion of the extended camera model into a matrix multiplication using homogeneous coordinates. On the left, the image coordinates  $\begin{pmatrix} u \\ v \\ 1 \end{pmatrix}$  are shown as a function of the camera parameters  $f_x, f_y, c_x, c_y$  and the world coordinates  $\begin{pmatrix} x \\ y \\ z \end{pmatrix}$ . A red arrow labeled  $\cdot z$  indicates the scaling of the image coordinates. The resulting equation shows the scaled image coordinates  $\begin{pmatrix} u \cdot z \\ v \cdot z \\ z \end{pmatrix}$  (circled in red) equal to the product of a matrix  $K$  (underlined in red) and the world coordinates  $\begin{pmatrix} x \\ y \\ z \end{pmatrix}$ . The matrix  $K$  is defined as  $\begin{pmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{pmatrix}$ .



# Homogene Koordinaten

$$\begin{pmatrix} x \\ y \\ 1 \end{pmatrix} : 2D\text{-Position} \leftarrow$$

$$\begin{pmatrix} x \\ y \\ 1 \end{pmatrix} \stackrel{\uparrow}{=} w \cdot \begin{pmatrix} x \\ y \\ 1 \end{pmatrix}$$

$$\begin{pmatrix} x \\ y \\ 0 \end{pmatrix} : 2D\text{-Richtung} \leftarrow$$

$$\begin{pmatrix} x \\ y \\ w \end{pmatrix} \stackrel{w \neq 0}{:} 2D\text{-Position}$$

$$\begin{pmatrix} x \\ y \\ w \end{pmatrix} \stackrel{\cdot 1/3}{=} \begin{pmatrix} x/3 \\ y/3 \\ 1 \end{pmatrix}$$

# Erweitertes Kameramodell

- Unter Verwendung homogener Koordinaten kann dies in Form einer Matrixmultiplikation geschrieben werden:

$$\begin{pmatrix} u \\ v \\ 1 \end{pmatrix} = \begin{pmatrix} \frac{f_x}{z} & 0 & \frac{c_x}{z} \\ 0 & \frac{f_y}{z} & \frac{c_y}{z} \\ 0 & 0 & \frac{1}{z} \end{pmatrix} \begin{pmatrix} x \\ y \\ z \end{pmatrix} \Rightarrow \begin{pmatrix} u \cdot z \\ v \cdot z \\ z \end{pmatrix} = \underbrace{\begin{pmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{pmatrix}}_K \begin{pmatrix} x \\ y \\ z \end{pmatrix}$$

- $K$  ist die **Kalibriermatrix der Kamera**

$$\begin{pmatrix} u \cdot z \\ v \cdot z \\ z \end{pmatrix} = K \begin{pmatrix} x \\ y \\ z \end{pmatrix}$$

# Erweitertes Kameramodell

Projektion  
Objekt  $\rightarrow$  Bild

$$\begin{pmatrix} u \cdot z \\ v \cdot z \\ z \end{pmatrix} = K \begin{pmatrix} x \\ y \\ z \end{pmatrix} \quad K = \begin{pmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{pmatrix}$$

Reproduktion  
Bild  $\rightarrow$  Objekt

$$\begin{pmatrix} x \\ y \\ z \end{pmatrix} = K^{-1} \begin{pmatrix} u \cdot z \\ v \cdot z \\ z \end{pmatrix} \quad K^{-1} = \begin{pmatrix} \frac{1}{f_x} & 0 & -\frac{c_x}{f_x} \\ 0 & \frac{1}{f_y} & -\frac{c_y}{f_y} \\ 0 & 0 & 1 \end{pmatrix}$$

Tiefeninfo

# Intrinsische und Extrinsische Kameraparameter

- Die Parameter in der Kalibriermatrix  $K$  werden als **intrinsische Parameter** bezeichnet.
- Die Beziehung zwischen Kamera-Koordinatensystem und Weltkoordinatensystem wird durch die **extrinsischen Parameter** beschrieben: eine Rotation  $R$  und eine Translation  $t$  im Raum.
- $R$  und  $t$  geben die Transformation vom Weltkoordinatensystem zum Kamerakoordinatensystem so an, dass für ein Weltpunkt  $x_w$  die Kamerakoordinaten  $x_c$  bestimmt werden durch:

$$x_c = R x_w + t$$

- Durch die Kombination von extrinsischen und intrinsischen Parametern wird die Projektion eines Punktes von Weltkoordinaten auf Bildkoordinaten durch die **Projektionsmatrix**  $P$  gegeben:

$$P = K \begin{matrix} \uparrow \\ (R|t) \end{matrix} \begin{matrix} \left( \begin{array}{ccc|c} a & b & c & x \\ d & e & f & x \\ g & h & i & z \end{array} \right) \end{matrix} \begin{matrix} \uparrow \\ 4 \times 3 \end{matrix}$$

$\begin{matrix} \uparrow & \uparrow \\ 3 \times 3 & R & t \end{matrix}$

# Kamerakalibrierung

- **Kamerakalibrierung** bedeutet die Bestimmung der extrinsischen und intrinsischen Parameter der Kamera
- Dies erfordert **mindestens 6 Korrespondenzen** zwischen nicht-koplanaren Weltpunkten und ihren Projektionen in die Bildebene. Für jede Korrespondenz gilt die Beziehung

$$\underbrace{\begin{pmatrix} u \cdot w \\ v \cdot w \\ w \end{pmatrix}}_{p_{12}} = P \begin{pmatrix} X \\ Y \\ Z \\ 1 \end{pmatrix} \quad | \cdot \frac{1}{p_{12}} \quad \text{mit} \quad P = (K R \mid K t) = \begin{pmatrix} p_1 & p_2 & p_3 & p_4 \\ p_5 & p_6 & p_7 & p_8 \\ p_9 & p_{10} & p_{11} & p_{12} \end{pmatrix}$$

- Hier gilt es, die unbekannt Parameter  $p_1$  bis  $p_{12}$  zu bestimmen

# Kamerakalibrierung

- Die Gleichung kann aufgelöst werden nach

$$u = \frac{p_1 X + p_2 Y + p_3 Z + p_4}{p_9 X + p_{10} Y + p_{11} Z + p_{12}}$$

$$v = \frac{p_5 X + p_6 Y + p_7 Z + p_8}{p_9 X + p_{10} Y + p_{11} Z + p_{12}}$$

- Da homogene Koordinaten verwendet werden, ändert die Multiplikation von  $P$  mit einem Faktor (ungleich Null) nichts. Daher kann die Gleichung normalisiert werden und z.B.  $p_{12} = 1$  gesetzt werden

- Die beiden Gleichungen lassen sich weiter umstellen zu

$$\begin{aligned} p_1 X + p_2 Y + p_3 Z + p_4 &= u p_9 X + u p_{10} Y + u p_{11} Z + u \cancel{p_{12}} \\ p_5 X + p_6 Y + p_7 Z + p_8 &= v p_9 X + v p_{10} Y + v p_{11} Z + v \cancel{p_{12}} \end{aligned} \quad |$$

# Kamerakalibrierung

- Jede Korrespondenz zwischen Welt und Bildpunkt ergibt **2 lineare Gleichungen**. Mit Hilfe von  $n$  Korrespondenzen ergibt sich das lineare Gleichungssystem  **$Ax = b$**  mit

$$A = \begin{pmatrix} \overset{P_1}{X_1} & \overset{P_2}{Y_1} & \overset{P_3}{Z_1} & 1 & \overset{P_5}{0} & \overset{P_6}{0} & \overset{P_4}{0} & \overset{P_8}{0} & \overset{P_9}{-u_1 X_1} & \overset{P_{10}}{-u_1 Y_1} & \overset{P_{11}}{-u_1 Z_1} \\ 0 & 0 & 0 & 0 & X_1 & Y_1 & Z_1 & 1 & -v_1 X_1 & -v_1 Y_1 & -v_1 Z_1 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ \overset{P_1}{X_n} & \overset{P_2}{Y_n} & \overset{P_3}{Z_n} & 1 & \overset{P_5}{0} & \overset{P_6}{0} & \overset{P_4}{0} & \overset{P_8}{0} & \overset{P_9}{-u_n X_n} & \overset{P_{10}}{-u_n Y_n} & \overset{P_{11}}{-u_n Z_n} \\ 0 & 0 & 0 & 0 & X_n & Y_n & Z_n & 1 & -v_n X_n & -v_n Y_n & -v_n Z_n \end{pmatrix} \begin{matrix} \left. \vphantom{\begin{matrix} X_1 \\ Y_1 \\ Z_1 \end{matrix}} \right\} 2 \\ \left. \vphantom{\begin{matrix} X_n \\ Y_n \\ Z_n \end{matrix}} \right\} 2 \end{matrix} \quad A: 11 \times 2n$$



$$\mathbf{x} = \begin{pmatrix} p_1 \\ \dots \\ p_{11} \end{pmatrix} \in \mathbb{R}^{11} \quad \mathbf{b} = \begin{pmatrix} u_1 \\ v_1 \\ \dots \\ u_n \\ v_n \end{pmatrix} \in \mathbb{R}^{2n}$$

# Kamerakalibrierung

- Jede Korrespondenz zwischen Welt und Bildpunkt ergibt 2 lineare Gleichungen. Mit Hilfe von  $n$  Korrespondenzen ergibt sich das lineare Gleichungssystem  $A \mathbf{x} = \mathbf{b}$  mit

$$A = \begin{pmatrix} X_1 & Y_1 & Z_1 & 1 & 0 & 0 & 0 & 0 & -u_1 X_1 & -u_1 Y_1 & -u_1 Z_1 \\ 0 & 0 & 0 & 0 & X_1 & Y_1 & Z_1 & 1 & -v_1 X_1 & -v_1 Y_1 & -v_1 Z_1 \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ X_n & Y_n & Z_n & 1 & 0 & 0 & 0 & 0 & -u_n X_n & -u_n Y_n & -u_n Z_n \\ 0 & 0 & 0 & 0 & X_n & Y_n & Z_n & 1 & -v_n X_n & -v_n Y_n & -v_n Z_n \end{pmatrix}$$

$$\mathbf{x} = \begin{pmatrix} p_1 \\ \dots \\ p_{11} \end{pmatrix} \quad \mathbf{b} = \begin{pmatrix} u_1 \\ v_1 \\ \dots \\ u_n \\ v_n \end{pmatrix}$$





# Kamerakalibrierung

- Die optimale Lösung  $x^*$  mit Hilfe der Kleinste-Quadrate-Methode für ein solches überbestimmtes lineares Gleichungssystem ergibt sich aus der Lösung von

$$A^T A x^* = A^T b$$

was sich auflösen lässt zu






$$x^* = (A^T A)^{-1} A^T b$$

wobei  $(A^T A)^{-1}$  mit der Moore-Penrose Pseudoinversen bestimmt werden kann

→ Fehler minimieren  
Kamera parameter

# Inhalt

- Bildrepräsentation
- Kameramodell
- **Filteroperationen**
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- Punktwolken
- SLAM
- Anwendungsbeispiel



# Filteroperationen

- **Filter** in der Bildverarbeitung  
auch *spatial filters*, *spatial masks*, *kernels*, *windows*
- Ein Filter besteht aus
  - einer Nachbarschaft (meist ein kleines Rechteck)
  - einer vordefinierten Operation
- Ein Filter wird auf alle Pixel des Bildes angewendet
  - Berechnung eines neuen Pixelwertes durch Anwendung der Filteroperation unter Berücksichtigung der Nachbarschaftspixel
- Eigenschaften eines **linearen Filters**

$$f(x + y) = f(x) + f(y)$$

$$f(\alpha x) = \alpha f(x)$$



additiv

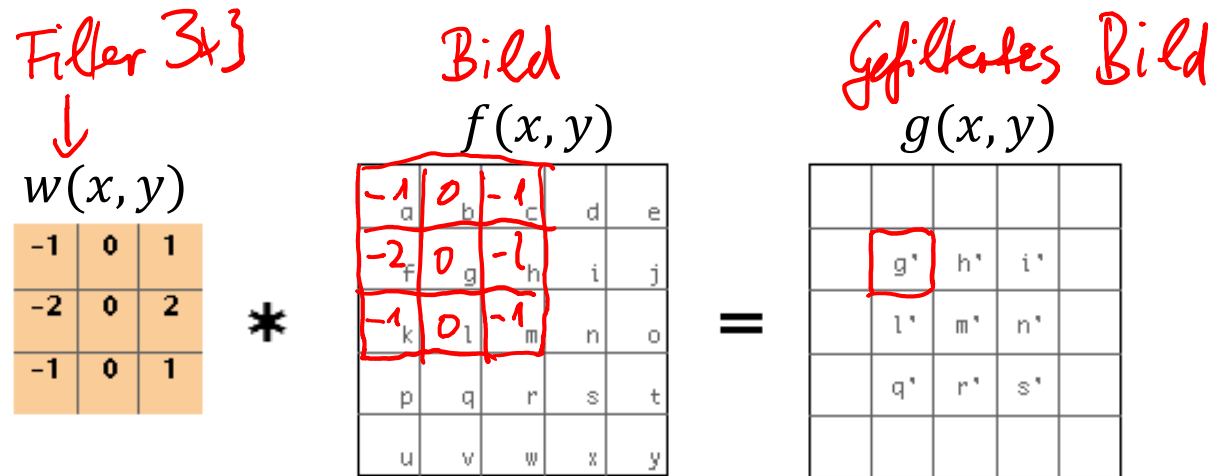


homogen

# Filter

- Die Anwendung eines Filters auf ein Bildelement wird dadurch realisiert, dass die Filtermaske auf dieses Element gelegt wird, die Maskenwerte mit den darunter liegenden Pixelwerten multipliziert werden und das Ergebnis aufsummiert wird.

- Beispiel:



$$\begin{aligned}
 g' = & (-1) \cdot a + 0 \cdot b + (-1) \cdot c \\
 & + (-2) \cdot f + 0 \cdot g + (-2) \cdot h \\
 & + (-1) \cdot k + 0 \cdot l + (-1) \cdot m
 \end{aligned}$$

# Filter

- Die Anwendung eines Filters auf ein Bildelement wird dadurch realisiert, dass die Filtermaske auf dieses Element gelegt wird, die Maskenwerte mit den darunter liegenden Pixelwerten multipliziert werden und das Ergebnis aufsummiert wird.

- Beispiel:

$$\begin{array}{|c|c|c|} \hline -1 & 0 & 1 \\ \hline -2 & 0 & 2 \\ \hline -1 & 0 & 1 \\ \hline \end{array} * \begin{array}{|c|c|c|c|c|} \hline a & b & c & d & e \\ \hline f & g & h & i & j \\ \hline k & l & m & n & o \\ \hline p & q & r & s & t \\ \hline u & v & w & x & y \\ \hline \end{array} = \begin{array}{|c|c|c|c|c|} \hline & & & & \\ \hline & g' & h' & i' & \\ \hline & l' & m' & n' & \\ \hline & q' & r' & s' & \\ \hline & & & & \\ \hline \end{array} \quad \text{Rond}$$

|    |   |   |   |   |   |
|----|---|---|---|---|---|
| -1 | 0 | 1 |   |   |   |
| a  | b | c | d | e |   |
| -2 | 0 | 2 |   |   |   |
| f  | g | h | i | j |   |
| -1 | 0 | 1 |   |   |   |
| k  | l | m | n | o |   |
|    | p | q | r | s | t |
|    | u | v | w | x | y |

$$g' = -a+c-2f+2h-k+m$$

|   |    |   |   |   |   |
|---|----|---|---|---|---|
|   | -1 | 0 | 1 |   |   |
| a | b  | c | d | e |   |
|   | -2 | 0 | 2 |   |   |
| f | g  | h | i | j |   |
|   | -1 | 0 | 1 |   |   |
| k | l  | m | n | o |   |
|   | p  | q | r | s | t |
|   | u  | v | w | x | y |

$$h' = (d+2i+n)-(b+2g+l)$$

|   |   |    |   |   |   |
|---|---|----|---|---|---|
|   |   | -1 | 0 | 1 |   |
| a | b | c  | d | e |   |
|   |   | -2 | 0 | 2 |   |
| f | g | h  | i | j |   |
|   |   | -1 | 0 | 1 |   |
| k | l | m  | n | o |   |
|   | p | q  | r | s | t |
|   | u | v  | w | x | y |

$$i' = (e+2j+o)-(c+2h+m)$$

# Filteroperationen - Grundlagen

- **Korrelation** ist der Prozess, bei dem eine Filtermaske über das Bild bewegt und die Summe der Produkte an jedem Punkt berechnet wird. Korrelation ist eine Funktion der Verschiebung des Filters

$$g(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) \cdot f(x + s, y + t)$$


- Die **Faltung** ist der gleiche Vorgang, nur dass der Filter zuerst um 180° gedreht wird

$$g(x, y) = \sum_{s=-a}^a \sum_{t=-b}^b w(s, t) \cdot f(x \ominus s, y \ominus t) \neq w * f$$


$$w * f = \int_0^x \int_0^y w(s, t) \cdot f(x - s, y - t) ds dt$$

# Filteroperationen - Ränder

- Was passiert an den Ränder?
  - Konstanter Wert (**Constant**),  
z.B. 0: Bild wird an den Rändern auf 0 gesetzt.
  - Umschlingen (**Wrap**):  
Bild wird „fortgesetzt“




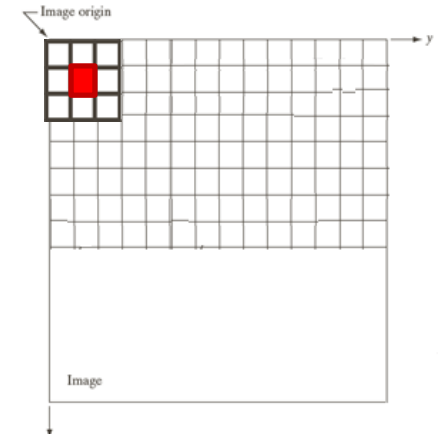
Constant




Wrap

# Filteroperationen - Ränder

- Was passiert an den Ränder?
  - Spiegeln (**Mirror, Reflect**):  
Bild wird an den Rändern gespiegelt
  - Wiederholen (**Clamp, Replicate**):  
Nehme letzten Wert



Mirror



Clamp



# Filteroperationen – Design (1)

Wie werden **Maskenkoeffizienten** definiert?

- Hängt davon ab, was der Filter tun soll!

|       |       |       |
|-------|-------|-------|
| $w_1$ | $w_2$ | $w_3$ |
| $w_4$ | $w_5$ | $w_6$ |
| $w_7$ | $w_8$ | $w_9$ |



Original

|   |   |   |
|---|---|---|
| 0 | 0 | 0 |
| 0 | 0 | 0 |
| 0 | 0 | 0 |



Ergebnis  
(Löschen)

# Filteroperationen – Design (2)

Wie werden **Maskenkoeffizienten** definiert?

- Hängt davon ab, was der Filter tun soll!

|       |       |       |
|-------|-------|-------|
| $w_1$ | $w_2$ | $w_3$ |
| $w_4$ | $w_5$ | $w_6$ |
| $w_7$ | $w_8$ | $w_9$ |



Original

|   |   |   |
|---|---|---|
| 0 | 0 | 0 |
| 0 | 1 | 0 |
| 0 | 0 | 0 |



Ergebnis  
(Identität)

# Filteroperationen – Design (3)

Wie werden **Maskenkoeffizienten** definiert?

- Hängt davon ab, was der Filter tun soll!

|       |       |       |
|-------|-------|-------|
| $w_1$ | $w_2$ | $w_3$ |
| $w_4$ | $w_5$ | $w_6$ |
| $w_7$ | $w_8$ | $w_9$ |



Original

|   |   |   |
|---|---|---|
| 0 | 0 | 0 |
| 0 | 0 | 1 |
| 0 | 0 | 0 |




Nach *links*  
um 1 Pixel verschoben

# Filteroperationen

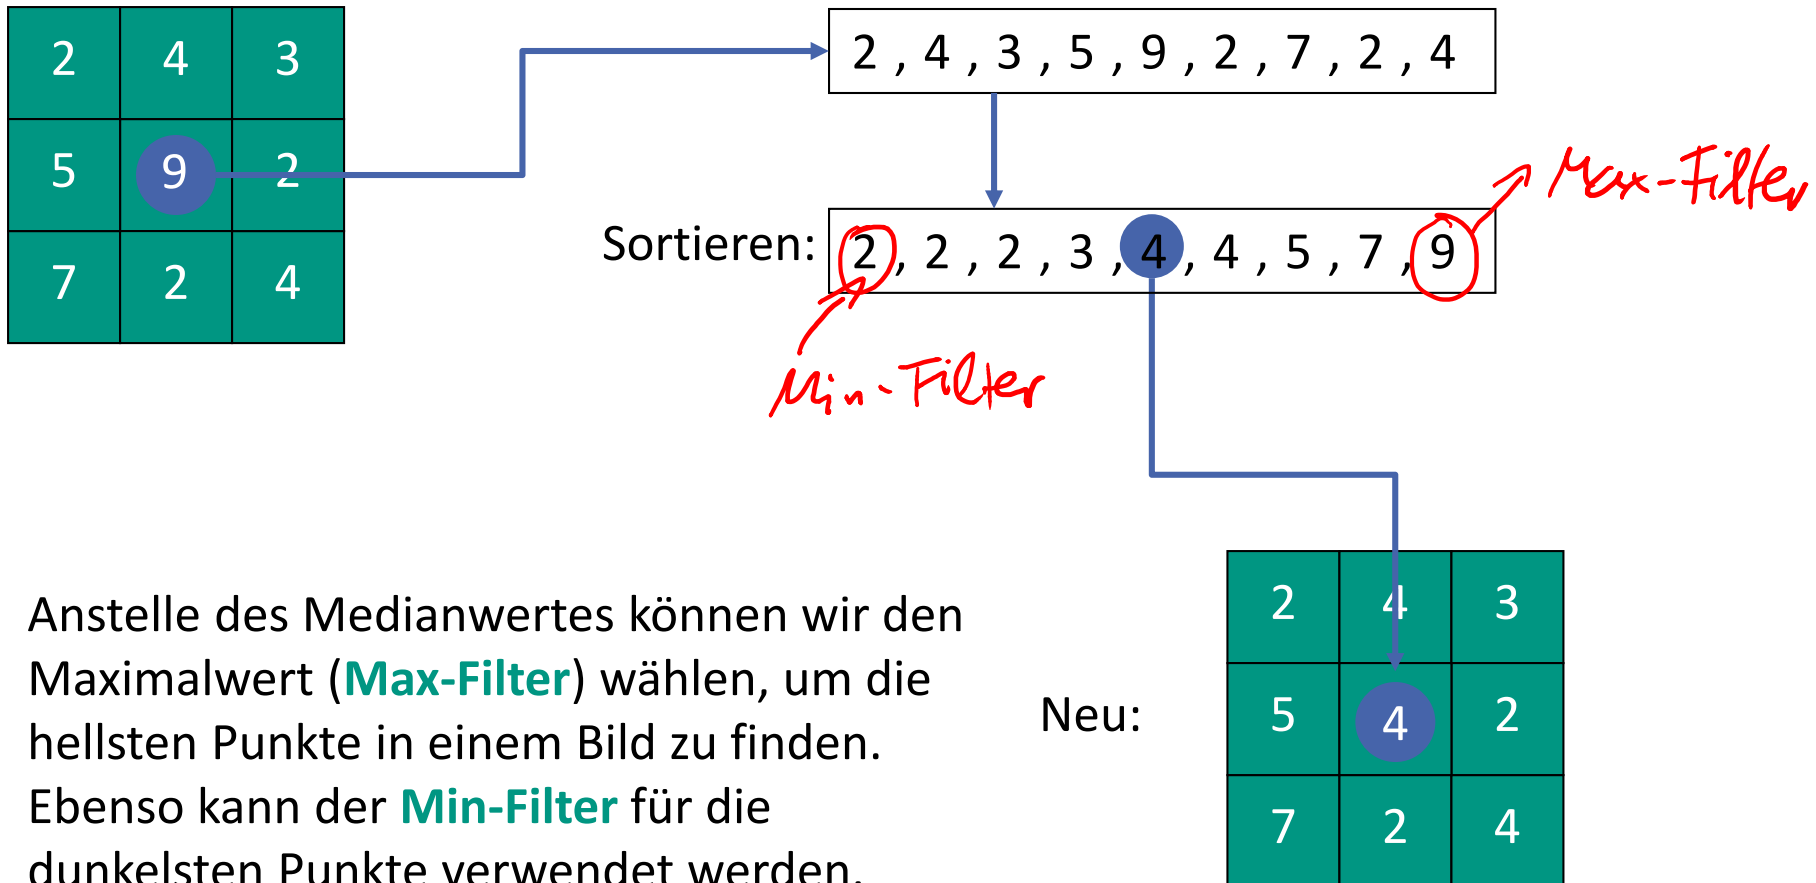
- **Tiefpassfilter:** Glättung, Rauschelimination
  - Medianfilter
  - Mittelwertfilter
  - Gauß-Filter
  
- **Hochpassfilter:** Kantendetektion
  - Prewitt
  - Sobel
  - Laplace
  
- **Kombinierte Operatoren**
  - Laplacian of Gaussian

# Medianfilter

- **Nichtlinearer** Filter zur Rauschunterdrückung
- Die Filterantwort basiert auf der Reihenfolge (Ranking) der Pixel, die in dem vom Filter umschlossenen Bildbereich enthalten sind.
- Schritte:
  - Wählen die Kernelgröße, um das zu filternde Pixel zu definieren. 3x3
  - Sortieren alle Grauwerte in Bereich des Kerns.
  - Bestimme mittleren Grauwert aus den sortierten Pixeln | Median
  - Wählen das Pixel als neuen Wert aus.




# Medianfilter: Beispiel




Anstelle des Medianwertes können wir den Maximalwert (**Max-Filter**) wählen, um die hellsten Punkte in einem Bild zu finden. Ebenso kann der **Min-Filter** für die dunkelsten Punkte verwendet werden. Beides sind nichtlineare Filter.

# Medianfilter: Beispiel


- Für bestimmte Arten von Rauschen, wie z.B. **Salz- und Pfefferrauschen**, bieten Medianfilter ausgezeichnete Rauschunterdrückungseigenschaften mit weniger Unschärfe als lineare Filter ähnlicher Größe!
  - Geeignet für Salz- und Pfefferrauschen
  - Nicht geeignet für Gaußsches Rauschen
- Bewahrt Kanten und entfernt Rauschen im Bild.



Original Bild beschädigt durch Salz- und Pfefferrauschen



3 X 3 Mittelwertfilter



3 X 3 Medianfilter

# Mittelwertfilter

- Ziel: Rauschunterdrückung
  - Beispiel: Durchschnitt aus einem Pixel und seine 8 Nachbarn; Größe beliebig wählbar
  - 3x3 Mittelwertfilter: Filtermaske

|               |               |               |
|---------------|---------------|---------------|
| $\frac{1}{9}$ | $\frac{1}{9}$ | $\frac{1}{9}$ |
| $\frac{1}{9}$ | $\frac{1}{9}$ | $\frac{1}{9}$ |
| $\frac{1}{9}$ | $\frac{1}{9}$ | $\frac{1}{9}$ |




|    |            |                           |            |    |    |    |    |
|----|------------|---------------------------|------------|----|----|----|----|
| 13 | 25         | 30                        | 34         | 40 | 46 | 60 | 76 |
| 45 | $(1/9)*50$ | $(1/9)*52$                | $(1/9)*55$ | 65 | 67 | 87 | 77 |
| 34 | $(1/9)*45$ | $(1/9)*55 \Rightarrow 52$ | $(1/9)*60$ | 54 | 45 | 56 | 65 |
| 45 | $(1/9)*50$ | $(1/9)*52$                | $(1/9)*48$ | 45 | 65 | 65 | 45 |
| 34 | 34         | 54                        | 56         | 57 | 58 | 67 | 70 |
| 45 | 46         | 46                        | 46         | 45 | 53 | 52 | 60 |
| 50 | 68         | 69                        | 60         | 70 | 70 | 78 | 79 |
| 68 | 70         | 78                        | 78         | 80 | 80 | 80 | 90 |

$$F_{\text{Mittelwert}} = \frac{1}{9} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$


$$g(x, y) = \sum_{s=-1}^1 \sum_{t=-1}^1 f(x - s, y - t) \cdot w(i, j)$$



# Mittelwertfilter: Beispiel



# Mittelwertfilter: Beispiel



# Gauß-Filter

- **Ziel:** Rauschunterdrückung, Glättung
- Definiert durch zweidimensionale Gauß-Funktion

$$\begin{array}{ccc}
 \blacksquare f(x, y) = \frac{1}{2\pi\sigma^2} e^{-\frac{x^2+y^2}{2\sigma^2}} & \begin{array}{c} \text{↔} \\ \text{↔} \\ \text{↔} \end{array} & F(u, v) = e^{-\frac{u^2+v^2}{2}\sigma^2} \\
 \text{Ortsbereich} & & \text{Frequenzbereich}
 \end{array}$$

- Approximation von  $f(x)$  durch einen  $3 \times 3$ -Filter für  $\sigma = 0.85$ :

$$F_{Gau\beta} = \frac{1}{16} \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix}$$

# Gauß-Filter II

- Die Stärke der Glättung ist ausschließlich durch den Parameter  $\sigma$  bestimmt:  
 Je größer  $\sigma$ , umso stärker die Glättung.
- Die Größe  $n \times n$  der Filtermaske beeinflusst die Güte der Approximation des Filters



Originalbild



$$\sigma^2 = 4$$



$$\sigma^2 = 16$$

# Filteroperationen

- **Tiefpassfilter:** Glättung, Rauschelimination
  - Medianfilter
  - Mittelwertfilter
  - Gauß-Filter
  
- **Hochpassfilter:** Kantendetektion
  - Prewitt
  - Sobel
  - Laplace
  
- **Kombinierte Operatoren**
  - Laplacian of Gaussian

# Filter – Prewitt

## ■ Prewitt-X Filter

- Approximiert durch

$$P_x = \frac{\partial f(x,y)}{\partial x}$$

$$p_x = \begin{pmatrix} f(x-1) & & f(x+1) \\ -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{pmatrix}$$

$$\Delta f = f(x+1) - f(x-1)$$

## ■ Prewitt-Y Filter



- Approximiert durch

$$P_y = \frac{\partial f(x,y)}{\partial y}$$

$$p_y = \begin{pmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{pmatrix}$$

## ■ Eigenschaften:

- Gute Ergebnisse bei Detektion von vertikalen bzw. horizontalen Kanten




## Filter – Prewitt (2)

- Kombination der Prewitt-Filter zur Bestimmung des Gradientenbetrags  $M$

$$M \approx \sqrt{P_x^2 + P_y^2}$$

- Danach: Schwellwertfilterung





# Filter – Sobel

- Ähnlich wie Prewitt
- Sobelfilter ist die Verkettung von Gaußfilter über Ableitung und Differenzenquotienten

## ■ Sobel-X Filter



Approximiert durch

$$s_x = \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix}$$

## ■ Sobel-Y Filter

Approximiert durch

$$s_y = \begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix}$$






## Filter – Sobel (2)

- Ähnlich wie Prewitt
- Kombination der Sobel-Filter zur Bestimmung des Gradientenbetrags  $M$

$$M \approx \sqrt{S_x^2 + S_y^2}$$

- Danach: Schwellwertfilterung



# Filter – Laplace (1)

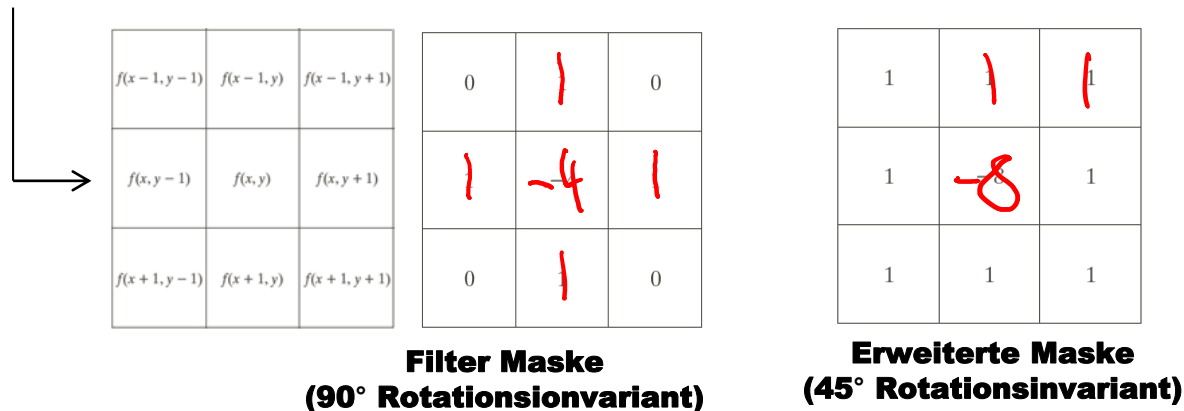
- Der Laplace-Operator eines Bildes ist ein linearer und rotationsinvarianter Operator zweiter Ordnung.

$$\Delta \nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2}$$

$\Delta f$  : Laplace - Operator

$$\left\{ \begin{array}{l} \frac{\partial^2 f}{\partial x^2} = f(x+1, y) + f(x-1, y) - 2f(x, y) \\ \frac{\partial^2 f}{\partial y^2} = f(x, y+1) + f(x, y-1) - 2f(x, y) \end{array} \right.$$

$$\Delta \nabla^2 f = f(x+1, y) + f(x-1, y) + f(x, y+1) + f(x, y-1) - 4f(x, y)$$



die Koeffizienten der Maskensumme sind gleich Null, was darauf hindeutet, dass die Antwort in den Bereichen konstanter Intensität gleich Null ist.

# Filter – Laplace (2)

Laplace-Operator:

$$\nabla^2 f(x, y) = \frac{\partial^2 f(x, y)}{\partial x^2} + \frac{\partial^2 f(x, y)}{\partial y^2}$$

$$\nabla^2 \approx \begin{pmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{pmatrix}$$




Nulldurchgänge (Zero-Crossings)  
definieren Kanten

Die Kanten sind dünner als bei Prewitt oder Sobel.

# Filter – Laplace (3)

Variation des **Laplace-Operator**:

$$\nabla^2 \approx \begin{pmatrix} 1 & 1 & 1 \\ 1 & -8 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$




Stärkere, aber mehr störende  
Kanten

# Filteroperationen

- **Tiefpassfilter:** Glättung, Rauschelimination
  - Medianfilter
  - Mittelwertfilter
  - Gauß-Filter
  
- **Hochpassfilter:** Kantendetektion
  - Prewitt
  - Sobel
  - Laplace
  
- **Kombinierte Operatoren**
  - Laplacian of Gaussian

# Filter – Laplacian of Gaussian( LoG)

- Der Laplace-Operator ist sehr rauschempfindlich
- Wesentlich bessere Ergebnisse werden erzielt, wenn man das Bild mit einem Gauß-Filter glättet und dann den Laplace-Operator (Laplacian of Gaussian, LoG) verwendet:



$$LoG(f(x, y)) = \Delta (f(x, y) * g(x, y))$$

$g$  bezeichnet die Filterfunktion eines Gauß-Filters.

# Hauptmerkmale des LoG-Operators

- Gaußsche Teil des Operators ist ein **Tiefpassfilter**, der das Bild verwischt (glättet) und so die Intensität von Strukturen (z.B. Rauschen) auf Skalen reduziert, die viel kleiner sind als Sigma  $\sigma$ .
- Im Gegensatz zum Mittelwertfilter ist es bei der Gaußschen Filter unwahrscheinlich, dass Artefakte wie z.B. "Treppenhaus"-Effekte auftreten, die im Originalbild nicht vorhanden sind.
- Der Laplace-Operator (die zweite Ableitung) ist invariant zur Rotation, die gleichermaßen auf Intensitätsänderungen in **jeder Maskenrichtung** reagiert. Auf diese Weise können wir vermeiden, mehrere Masken zu verwenden, um die stärkste Reaktion an jedem Punkt des Bildes zu berechnen.
- Nulldurchgänge (*Zero Crossings*) des Laplacian entsprechen den Kanten.



$$\frac{1}{9} \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$

$$\frac{1}{16} \begin{pmatrix} 1 & 2 & 1 \\ 2 & 4 & 2 \\ 1 & 2 & 1 \end{pmatrix}$$





# Filter – Laplacian of Gaussian( LoG)

## Approximation

Faltung mit der Matrix 5x5





$$\Delta F(x, y) = \begin{pmatrix} 0 & 0 & -1 & 0 & 0 \\ 0 & -1 & -2 & -1 & 0 \\ -1 & -2 & 16 & -2 & -1 \\ 0 & -1 & -2 & -1 & 0 \\ 0 & 0 & -1 & 0 & 0 \end{pmatrix}$$



Stärkere Kanten,  
Weniger Rauschen

# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- **Segmentierung**
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- Punktwolken
- SLAM
- Anwendungsbeispiel




# Segmentierung

- **Segmentierung** ist die Aufteilung eines Bildes in aussagekräftige Segmente
- Jedes Pixel wird mindestens einem Segment zugeordnet
- Identifikation von interessante Bildregionen für die Analyse, Erkennung und Klassifikation

## Mögliche Verfahren:

- Schwellwertfilterung
- Clustering
- Kantenextraktion
- Region-Growing



# Segmentierung: Schwellwertfilterung (1)

- Schwellwertfilterung zur Konvertierung eines Grauwertbildes in ein binäres Bild
- Intensität von jedem Pixel  $(u, v)$  wird mit einem vordefinierten **Schwellwert**  $T$  abgeglichen

$$Img'(u, v) = \begin{cases} 255, & \text{falls } Img(u, v) > T \\ 0, & \text{sonst} \end{cases}$$



## Segmentierung: Schwellwertfilterung (2)

- Oft können Objekte über ihre **Farbe** segmentiert werden:
  - Menschliche Haut
  - Einfarbige Objekte
  
- Beispiel:
  - Intervallschranken im *HSV*-Farbraum:

$$\text{Img}'(u, v) = \begin{cases} 255, & \text{falls } \begin{array}{l} H_{max} \geq \text{Img}_H(u, v) \geq H_{min}, \\ S_{max} \geq \text{Img}_S(u, v) \geq S_{min}, \\ V_{max} \geq \text{Img}_V(u, v) \geq V_{min} \end{array} \\ 0, & \text{sonst} \end{cases}$$

*Farbe*  
*Sättigung*  
*Helligkeit*

- Problem:
  - Wechselnde Lichtbedingungen
  - Reflexionen, Schattenwürfe

## Einschub: Probleme von Lichtverhältnissen





# Segmentierung: Beispielanwendung

- Beispielanwendung: Objekterkennung und -lokalisierung



Eingabebild



Ergebnis der Segmentierung

# Anwendungsbeispiel : Farbsegmentierung


- Segmentierung der Hautfarbe und Verfolgung von Gesicht und Händen






# HSV-Segmentierung Wie kann die rote Region extrahiert werden? (HSV)


Original Bild




Farbnuance



Sättigung



Helligkeit





HSV

**Segmentierung** ist die **Unterteilung** eines Bildes in **plausible** Regionen



Binärmaske durch Schwellwertfilterung des **Sättigungsbildes** (>10%)

Farbnuancenwerte des Bildes werden mit der Maske multiplizieren.



**Schwellwertfilterung**  
Anwenden auf das Histogramm!

Berechnung des **Histogramms**




Segmentiertes Bild

# RGB Segmentierung

Original Bild

Wie kann die rote Region extrahiert werden? (RGB)




Definiere region of interest (ROI).

**Euklidische Distanz**  
der beiden Farbvektoren!

$$D(z, a) \leq D_0$$

$$D(z, a) = \|z - a\| = [(z_R - a_R)^2 + (z_G - a_G)^2 + (z_B - a_B)^2]^{1/2}$$




**Unterschiedliche Bereiche!**

**Klassifiziere** jedes RGB Pixel, ob der Farbwert in einem spezifizierten Bereich liegt oder nicht!


# RGB Segmentierung

Wie kann die rote Region extrahiert werden? (*RGB*)



Original Bild

$$D(z, a) \leq D_0$$







Segmentiertes Bild



**Klassifiziere** jedes *RGB* Pixel, ob der Farbwert in einem spezifizierten Bereich liegt oder nicht!

# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- Segmentierung
- **Morphologische Operatoren**
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- Punktwolken
- SLAM
- Anwendungsbeispiel




# Motivation: Farbsegmentierung

- Problem bei der Segmentierung: Artefakte, unvollständige Segmentierung




Eingabebild




Ergebnis Segmentierung

# Morphologische Operatoren

- Morphologische Operatoren werden oft für die Nachbearbeitung binärer Bilder verwendet (z.B. Ergebnis einer Farbsegmentierung)
- Gängige morphologische Operatoren:
  - **Dilatation**  
Die Dilatation vergrößert Pixel zu größeren Bereichen
  - **Erosion**  
Die Erosion entfernt vereinzelte Pixel und schwach zusammenhängende Pixelgruppen
- Der Effekt eines morphologischen Operators hängt von der Größe und der Form der berücksichtigten Pixelnachbarschaft ab. Definiert durch das strukturierende Element/Kernel



4er-Nachbarschaft



8er-Nachbarschaft

# Morphologische Operatoren: Erosion

---

**Algorithmus 20** Erosion( $I, n$ )  $\rightarrow I'$

---


```

k := div((n - 1), 2)
for all pixels (u, v) in  $I'$  do
   $I'(u, v) := 0$ 
end for
for v := k to h - k - 1 do
  for u := k to w - k - 1 do
    if  $I(u, v) = q$  then
      for i := -k to k do
        for j := -k to k do
          if  $I(u + j, v + i) \neq q$  then
            goto NEXT
          end if
        end for
      end for
       $I'(u, v) = q$ 
    end if
    NEXT:
  end for
end for

```


---

Bildhöhe  $h$ ,  
Bildbreite  $w$



# Morphologische Operatoren: Erosion, Beispiel

- Beispielanwendung einer Erosion



Eingabebild



Ergebnisbild



# Morphologische Operatoren: Dilation

---

## Algorithmus 19 Dilatation( $I, n$ ) $\rightarrow I'$

---


```

 $k := \text{div}((n - 1), 2)$ 
for all pixels  $(u, v)$  in  $I'$  do
   $I'(u, v) := 0$ 
end for
for  $v := k$  to  $h - k - 1$  do
  for  $u := k$  to  $w - k - 1$  do
    if  $I(u, v) = q$  then
      for  $i := -k$  to  $k$  do
        for  $j := -k$  to  $k$  do
           $I'(u + j, v + i) = q$ 
        end for
      end for
    end if
  end for
end for

```

---

Bildhöhe  $h$ ,  
Bildbreite  $w$




# Morphologische Operatoren: Dilatation, Beispiel

- Beispielanwendung einer Dilatation



Eingabebild



Ergebnisbild

# Morphologische Operatoren: Öffnen & Schließen

## Öffnen:




- Anwendung von Erosion danach Dilatation
- Entfernt dünne Stege oder kleine außenliegende Objekte

## Schließen:

- Anwendung von Dilatation danach Erosion
- Überbrückung kleiner Distanzen und Schließung von inneren Löchern

# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- **Canny-Kantendetektor**
- Tiefenkameras
- Visual Servoing
- Punktwolken
- SLAM
- Anwendungsbeispiel



# Canny-Kantendetektor

- Nach John F. Canny aus dem Jahre 1986
- Der Canny-Kantendetektor ist weit verbreitet und bezüglich der Leistung im Vergleich zu anderen Kantendetektoren im Allgemeinen überlegen.
- Ziel war es den “**optimalen**” Kantendetektor zu finden:
  - Gute Detektion
  - Gute Lokalisierung
  - Minimale Antwort (“dünne Linien”)
- Canny-Kantendetektor berechnet binäre Antwort (üblicherweise 0: keine Kante, 255: Kante)
- Subpixelgenauigkeit durch Erweiterung möglich

# Canny-Kantendetektor

Das Prinzip basiert auf drei Grundsätzen:

1. **Geringe Fehlerrate:** Alle Kanten sollen gefunden werden und detektierte Kanten sollten so nah wie möglich an den realen Kanten sein.
2. **Kantenpunkte sollen gut detektiert werden:** Distanz zwischen detektierten Kantenpunkten und dem Zentrum der realen Kanten soll minimal sein.
3. **Eindeutigkeit:** Der Detektor soll nur ein Punkt, nicht mehrere Kantenpunkte, zu einem realen Kantenpunkt liefern.

# Canny-Kantendetektor: Algorithmus

1. Rauschunterdrückung: Gauß-Filter
2. Berechnung der Gradienten in horizontaler und in vertikaler Richtung  
 $Prewitt_x / Prewitt_y$  oder  $Sobel_x / Sobel_y$

a) Berechnung der Richtung:  $\phi = \text{atan}\left(\frac{g_y}{g_x}\right)$

b) Einteilung der Richtung in vier (oder acht) Quadranten:

1 :  $[-67.5^\circ, -22.5^\circ)$

2 :  $[-22.5^\circ, 22.5^\circ)$ ,

3 :  $[22.5^\circ, 67.5^\circ)$

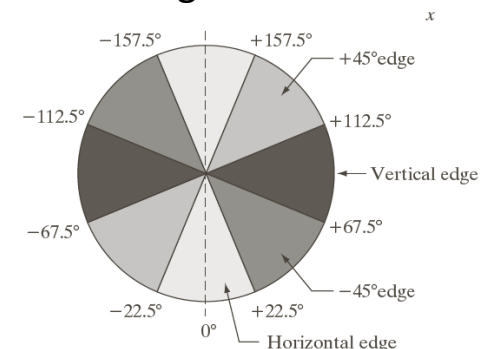
4 :  $[-90^\circ, -67.5^\circ)$  oder  $[67.5^\circ, 90^\circ)$

c) Magnitude  $M = \sqrt{g_x^2 + g_y^2}$

3. Non-Maximum Supression


4. Hysterese-Schwelwertverfahren

Einteilung in 8 Quadrante:



# Canny-Kantendetektor: Non-Maximum Suppression


- Der Canny-Kantendetektor verwendet **Non-Maximum Suppression** (d.h. eine Kantenausdünnung)
  - Gradient muss lokales Maximum sein
  - Betrachtung der zwei direkten Nachbarn entlang der Gradientenrichtung
  - Überprüfung erfolgt gemäß dem jeweiligen Quadranten





# Canny-Kantendetektor : Non-Maximum Suppression

Definiere vier Kantenorientierung




Definiere einen Bereich um alle möglichen Kantenrichtungen in vier Richtungen zu unterteilen

Kantennormale: 
$$\phi(x, y) = \tan^{-1} \left( \frac{g_y}{g_x} \right)$$

1. Definiere eine  $3 \times 3$  Region ( $p_1$  bis  $p_9$ ) um jeden Punkt  $(x, y)$  in  $\phi(x, y)$ .
2. Bestimme die Richtung der Kante welche nah bei  $\phi(x, y)$  ist. (In diesem Beispiel ist  $p_5$  horizontal.)
3. Wenn der Wert im Zentrum der Mangitude  $M$  kleiner als einer der beiden Nachbarn in Richtung der Kantennormale ist (im Beispiel  $p_2$  und  $p_8$ ), dann setze  $M = 0$  (Suppression!)

Beispiel:  $p_1 \dots p_9$



# Canny-Kantendetektor: Schwellwertverfahren

## ■ Hysterese-Schwellwertverfahren

1. Verwendung von **zwei Schwellwerten**: low / high
2. Liegt der Betrag des Gradienten für ein Pixel über dem Schwellwert „high“, so wird es als Teil einer Kante akzeptiert
3. Liegt der Betrag des Gradienten für ein Pixel unter dem Schwellwert „low“, so wird es als Teil einer Kante abgelehnt
4. Ausgehend von den akzeptierten Pixel werden Kanten (rekursiv) verfolgt:
  - Überprüfung der acht direkten Nachbarn
  - Betrag Gradient muss über Schwellwert low liegen





Anmerkung: Lokale Maximalitätsbedingung aus Schritt 3 muss in jedem Fall erfüllt sein!

# Canny-Kantendetektor: Beispiel



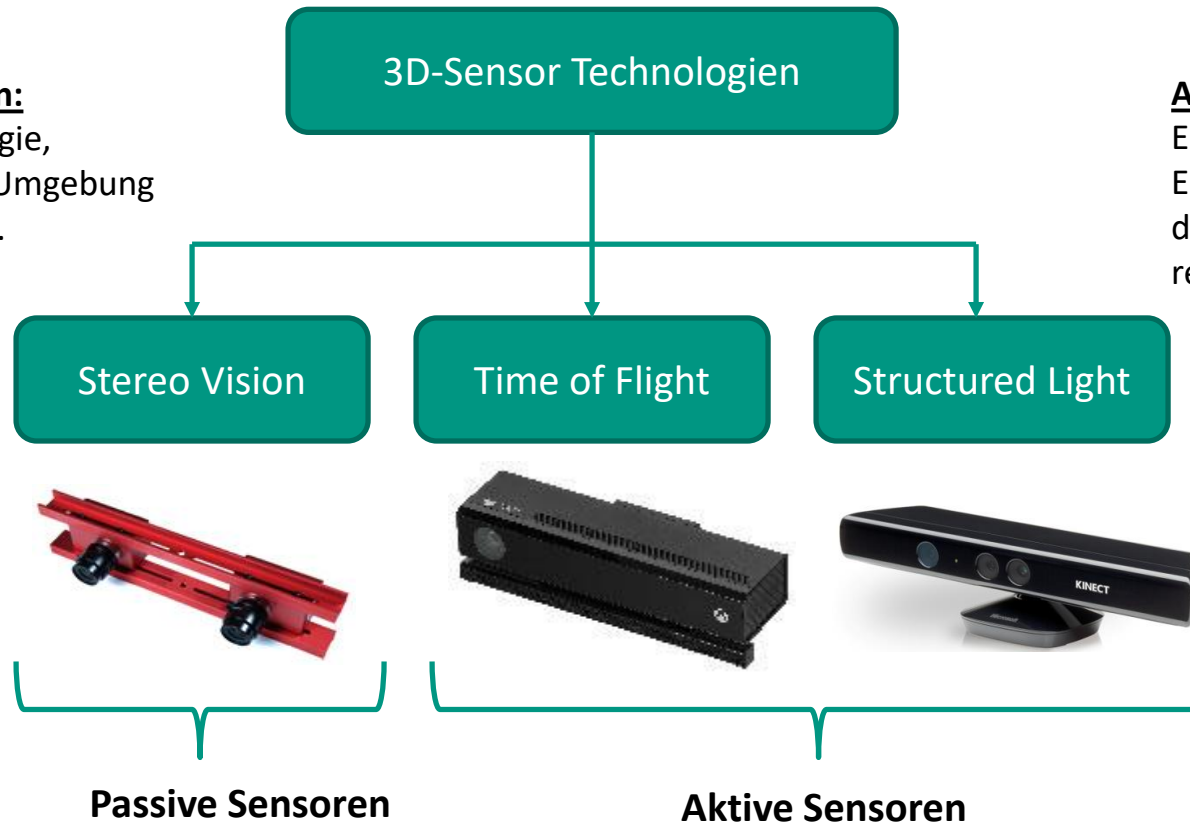
# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- **Tiefenkameras**
- Visual Servoing
- Punktwolken
- SLAM
- Anwendungsbeispiel



**Passive Sensoren:**  
Empfangen Energie,  
welche von der Umgebung  
abgestrahlt wird.

**Aktive Sensoren:**  
Erzeugen und senden  
Energie aus, die von  
der Umgebung  
reflektiert wird.



# Stereo Vision I

- Brennweite  $f$
- Baseline  $B = b$


- Objektdistanz  $Z$
- Objektpunkt  $P$
- Bildpunkte

- $p = (x_{Left}, y_{Left})^T$ ,

- $p' = (x_{Right}, y_{Right})^T$


- Disparität  $d$

$$Z = \frac{b \cdot f}{x_{Left} - x_{Right}} = \frac{b \cdot f}{d}$$




# Stereo Vision II

$$Z = \frac{b \cdot f}{x_{Left} - x_{Right}} = \frac{b \cdot f}{d}$$



Disparitäten für **nähere** Objekten haben eine **geringere** Varianz.  
 Für **entfernte** Objekte **steigt** diese Varianz, was zu **ungenauen** Tiefenmessungen führt.

# Stereo Vision III



## Vorteile

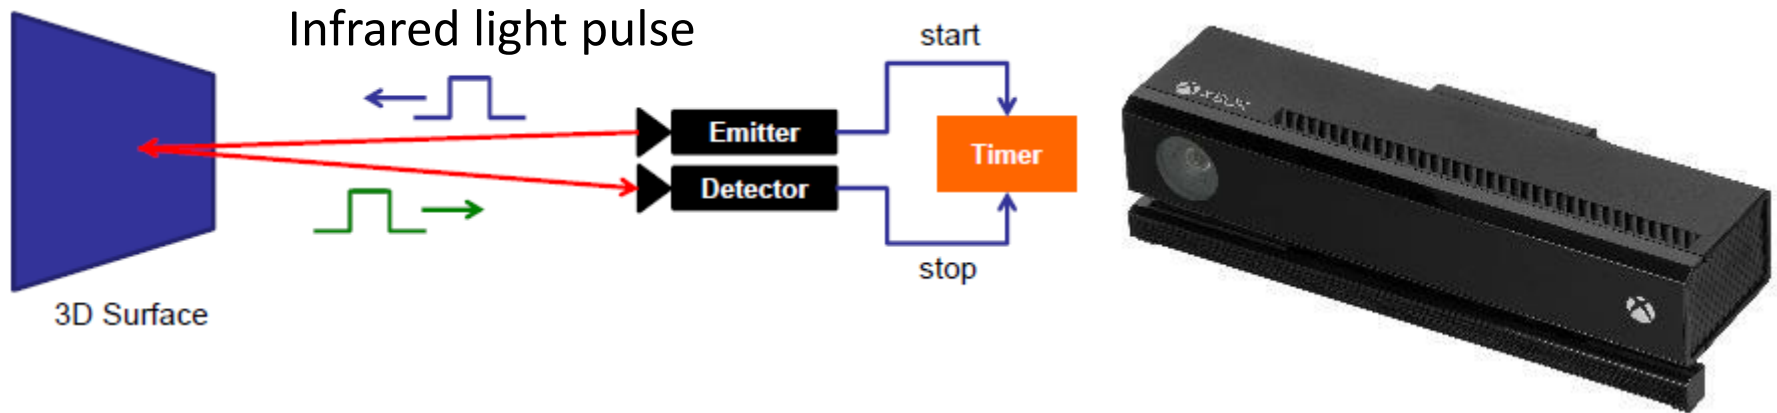
- Einstellbare Brennweiten/Baseline
- Keine explizite Lichtquelle erforderlich

## Nachteile




- Mindestens zwei Kameras
- Korrespondenzproblem bei homogenen Flächen





# Time of Flight




## Vorteile

-  Keine explizite Tiefenberechnung notwendig
-  Hohe Bildrate (bis zu 100 fps)
-  Robust gegenüber den meisten Oberflächen (Kein Korrespondenzproblem)



## Nachteile

-  Niedrige Auflösung (512 x 424 px)
-  Interferenz mit anderen Lichtquellen und Reflektionen



# Structured Light



## Vorteile





-  Preiswert
-  Kein Korrespondenzproblem auf homogenen Flächen

## Nachteile

-  Eingeschränkte Reichweite (2 m)
-  Erfordert bestimmte Lichtverhältnisse (nur für den Innenraum geeignet)

# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- **Visual Servoing**
- Punktwolken
- SLAM
- Anwendungsbeispiel

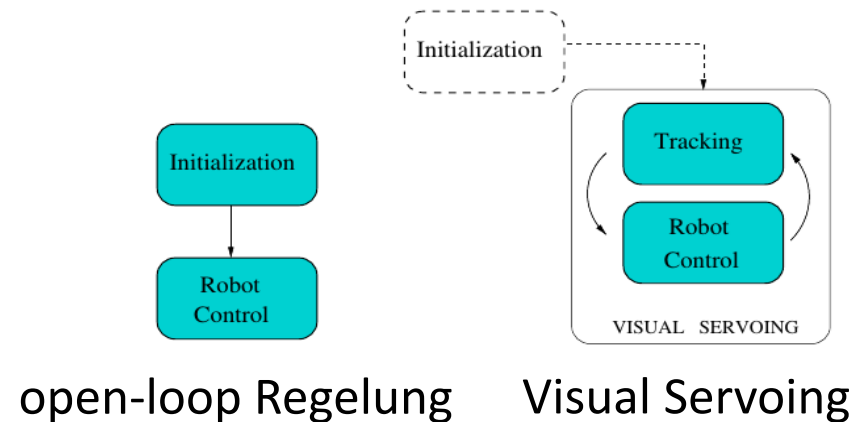


# Visual Servoing - Motivation

- Der Ausdruck **Visual Servoing** beschreibt Verfahren bei denen visuelle Eingabedaten genutzt werden, um die Bewegung eines Roboters zu steuern.

## Motivation

- Modellfehler  
z.B. Kinematik
- Fehler bei der Ausführung  
z.B. fehlerhafte Positionierungen der Robotergelenke
- Überwachung der Szene  
z.B. Reaktion auf Kollisionen




F Chaumette, S Hutchinson, *Visual servo control - Part I - Basic approaches*, IEEE Robotics & Automation Magazine 13 (4), 82-90, 2006

Danica Kragic and Henrik I Christensen, *Survey on Visual Servoing for Manipulation*, Techn. Report, KTH, 2002

# Visual Servoing - Systemaufbau


## ■ Kamera-in-Hand (eye-in-hand)

- Kamera ist an dem Manipulator angebracht
- Bewegungen des Manipulators beeinflussen die Pose der Kamera



## ■ Externes (festes) Kamera System (eye-to-hand)

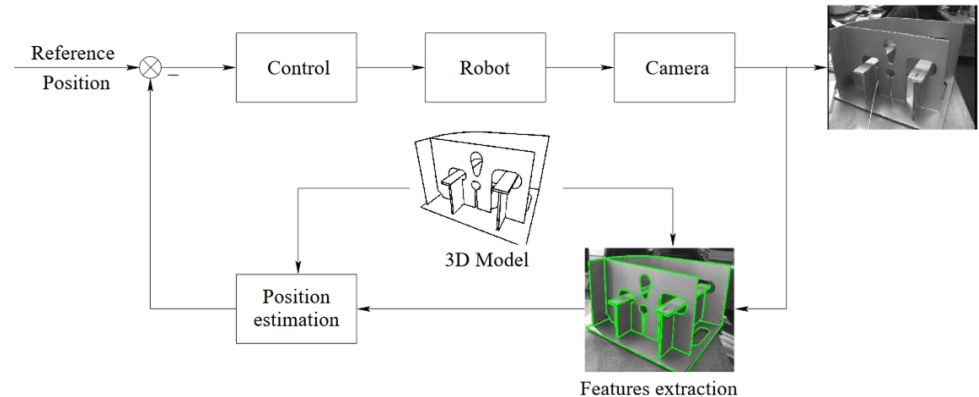
- Externes Kamerasystem wird zur Beobachtung der Bewegung genutzt



# Visual Servoing - Verfahren

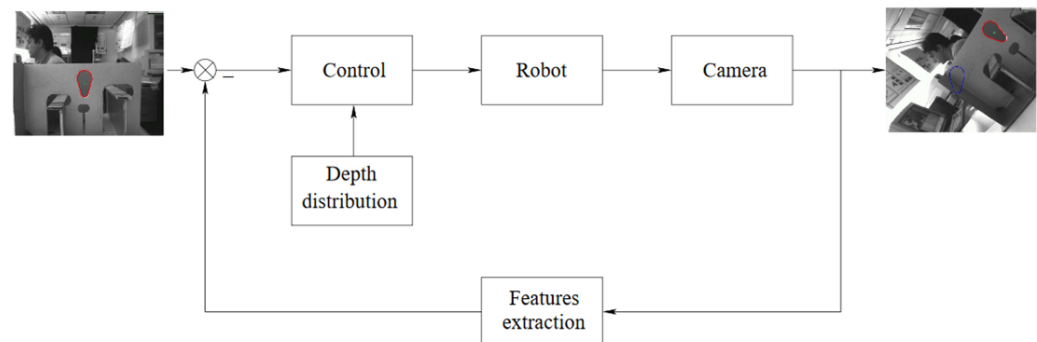
## ■ Positionsbasiertes Visual Servoing

- Position-based visual servo (PBVS)
- Einfache Regler
- 3D Rekonstruktion aufwendig



## ■ Bildbasiertes Visual Servoing

- Image-based visual servo (IBVS)
- Merkmalsextraktion einfach
- Komplexere Regelungsvorschriften

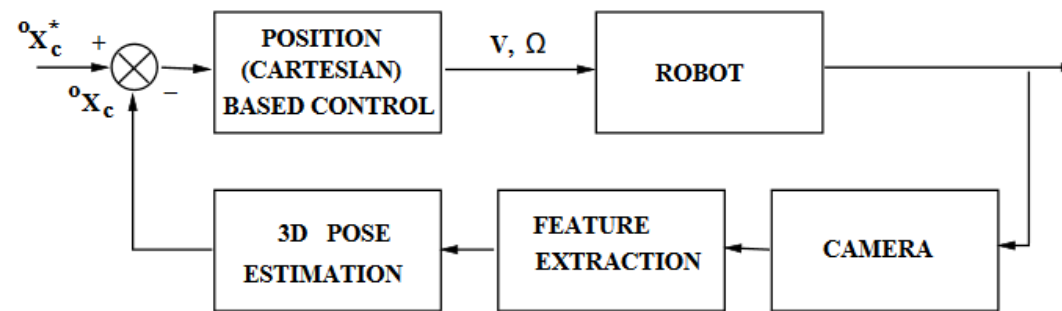



## ■ Hybride Verfahren

(z.B. 2,5D visual servo)


# Positionsbasiertes Visual Servoing

- Zielpose  $X_g$  ist vorgegeben
- Ablauf der Regelschleife
  - **3D Lage Schätzung:**  
Aktuelle Pose  $X_c$  des Zielobjektes (bzw. Hand) wird aus Bildmerkmalen extrahiert
  - **Regelvorgabe** (kartesisch):  
Differenz  $\Delta X = X_g - X_c$
  - **Kartesischer Regler** führt  $\Delta X$  aus
  - Ziel erreicht:  
Distanz  $\Delta X$  kleiner als Schwellwert



# Positionsbasiertes Visual Servoing

- Beispiel auf ARMAR-III





# Bildbasiertes Visual Servoing

## ■ Ansatz

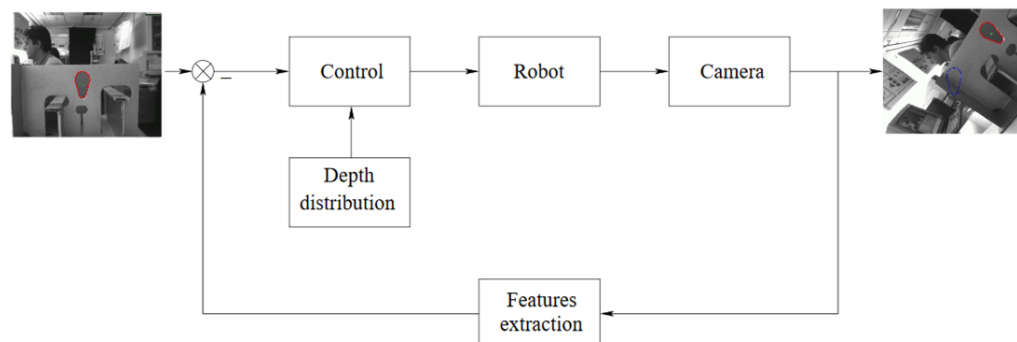
Die Bewegung des Manipulators ergibt sich aus der aktuellen und gewünschten Position von Bildmerkmalen

## ■ Bildmerkmale

Bildverarbeitungsmethoden zur Extraktion von Bildmerkmalen

## ■ Regelung


Geschwindigkeitsvorgaben werden direkt aus der aktuellen und gewünschten Stellung der Bildmerkmale erzeugt



# Bildbasiertes Visual Servoing

## ■ Bildmerkmal

Ein Bildmerkmal  $s = (u, v)^T$  ist die Projektion eines 3D Punktes  $P = (x, y, z)^T$  im Kamerabild.



## ■ Fehlerfunktion

- Aktuelle Position der Merkmale im Kamerabild (Zeitpunkt  $t$ ):  $s(t)$
- Gewünschte Zielposition der Merkmale im Kamerabild (konstant):  $s^*$
- Fehler:  $e(t) = s(t) - s^*$

# Bildbasiertes Visual Servoing

## ■ Interaction Matrix / Image Jacobian

Die **interaction matrix**  $L$  beschreibt die Beziehung zwischen der Bewegung eines Bildmerkmals  $s = (u, v)^T$  und des entsprechenden 3D Punktes  $P = (x, y, z)^T$

$$\dot{s} = L \dot{P}$$

■ Aus den Projektionsvorschriften (Lochkameramodell) ergibt sich

$$L = \begin{pmatrix} \frac{f}{z} & 0 & -\frac{u}{z} & -\frac{uv}{f} & \frac{f^2 + u^2}{f} & -v \\ 0 & \frac{f}{z} & -\frac{v}{z} & -\frac{f^2 + v^2}{f} & \frac{uv}{f} & u \end{pmatrix}$$

# Bildbasiertes Visual Servoing

## ■ Invertierung der Interaction Matrix

- Distanz  $z$  wird geschätzt
- Mehrere Merkmale werden beobachtet (mind. 3)
- Annahme: Kamera-In-Hand System  
Bewegung der 3D Punkte korrespondiert mit Bewegung der Kamera  $v_C$
- Daraus folgt:

$$\dot{e} = L v_C$$

- Mit  $\dot{e} = -\lambda e$  ergibt sich

$$v_C = -\lambda L^+ e$$

- Hierbei ist  $L^+$  die Pseudoinverse von  $L$
- Regelungseingabe  $v_C$  wird aus der Position der Bildmerkmale berechnet

# Visual Servoing für ARMAR-III

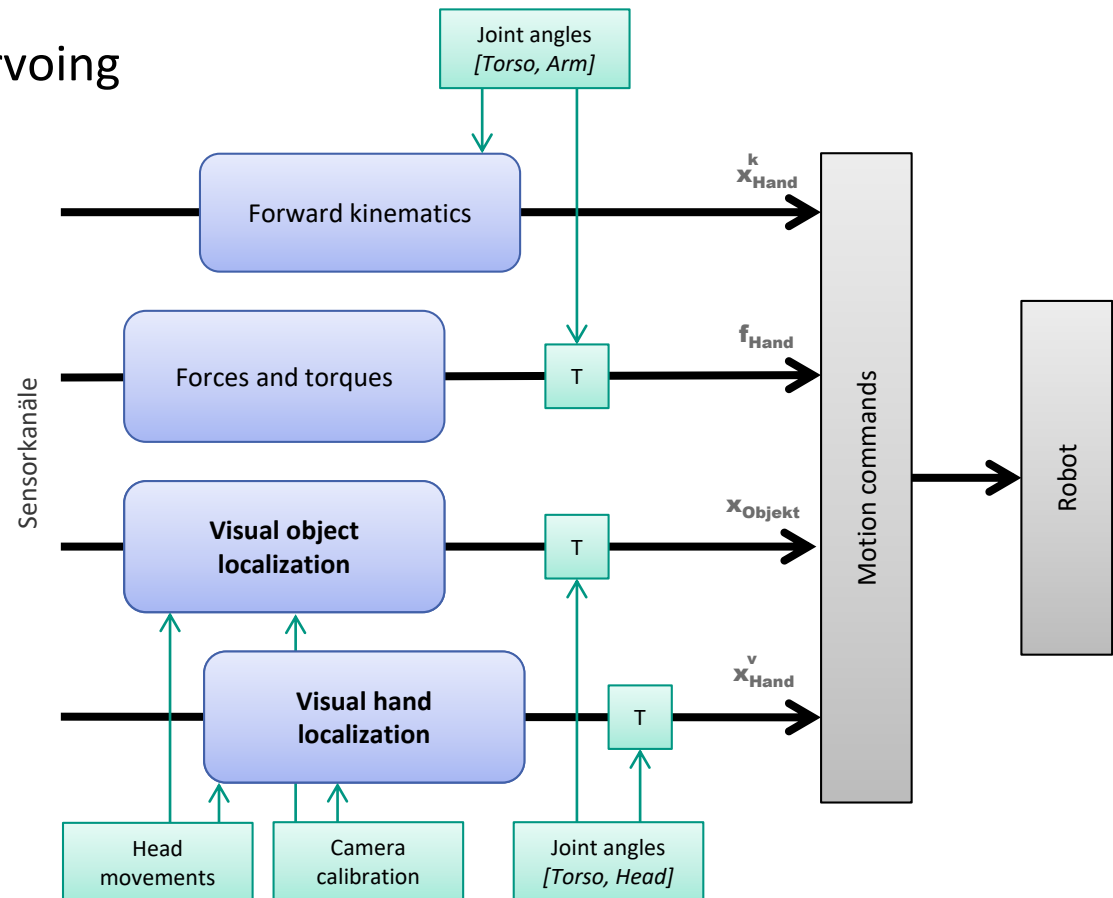
## ■ Ausführung von Greif und Manipulationsaufgaben

## ■ Positionsbasiertes Visual Servoing


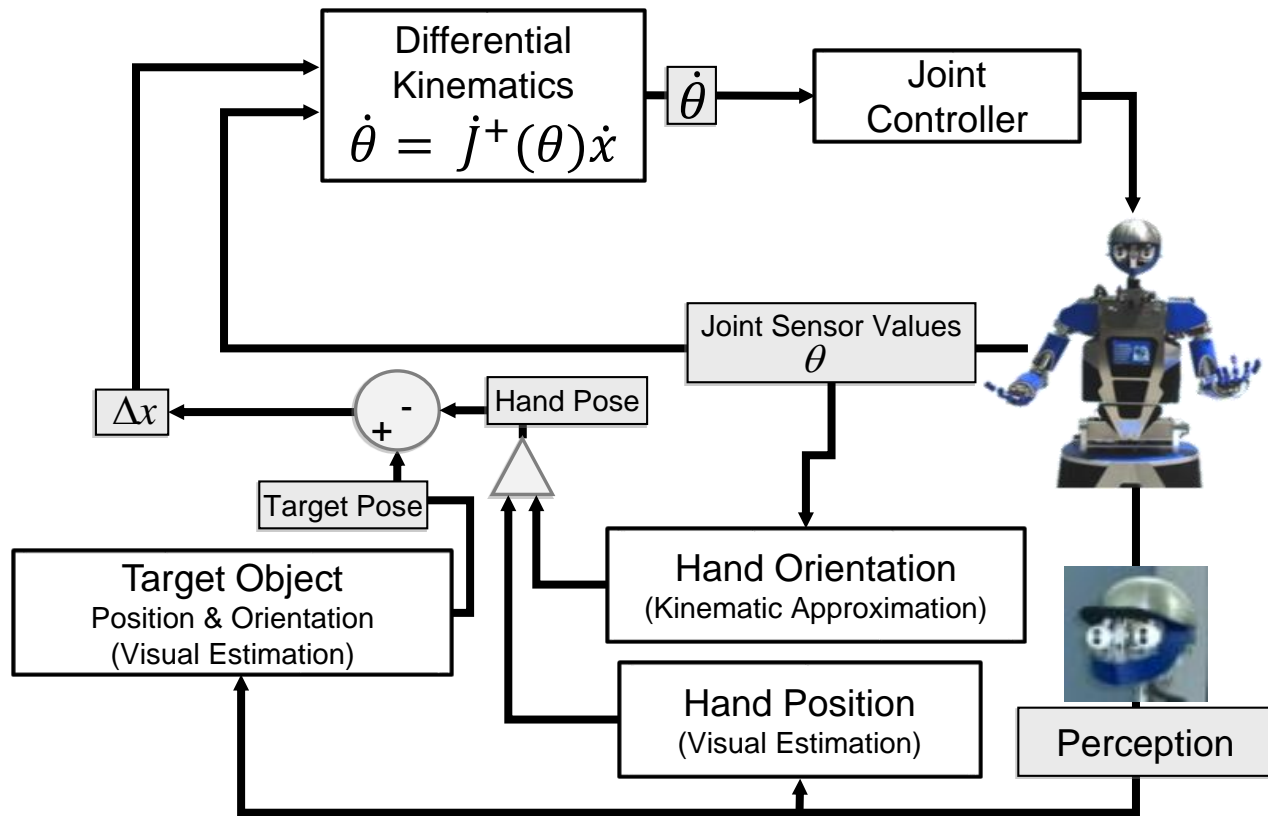
- Modellwissen
- Objektlokalisierung
- Handlokalisierung

## ■ Sensoren

- Kraft/Kontakt
- Kameras
- Interne Sensoren



# Positionsbasiertes Visual Servoing auf ARMAR-III









$$\dot{\theta} = j^+(\theta)\dot{x}$$

$$\delta^t = x_{vision}^t - x_{kinematic}^t$$





$$x_{tcp}^{t+1} = x_{kinematic}^{t+1} + \delta_{tcp}^t$$

# Ausführung von Manipulationsaufgaben



# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- **Punktwolken**
- SLAM
- Anwendungsbeispiel





# Point Clouds

- Eine **Punktwolke** ist eine **diskrete** Menge von **3D-Punkten** mit einem festen Koordinaten System.

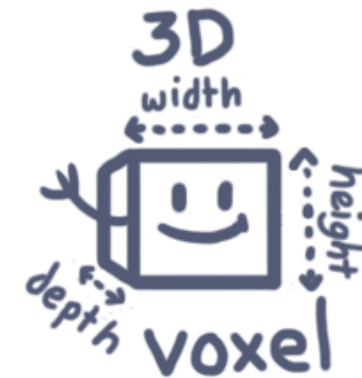


**Pixel = Picture Elements**




**2D Bild**

VS.



**Voxel = Volumetric Pixel**



**3D Punktwolke**


# Point Clouds

- Punktvolke  $P = \{(X, C) \mid X \in \mathbb{R}^3, C \in [0 \dots 255]^3 \subset \mathbb{N}_0^3\}$ 
  - $X = (x, y, z)$  Ortsinformation
  - $C = (r, g, b)$  Farbinformation
  - Es können weitere (Sensor-)informationen abgespeichert werden
- Zwei verschiedene Arten der Repräsentation
  - **Organisierte** Punktvolke (2D Array Format, Größe muss vorab bekannt sein)
  - **Unorganisierte** Punktvolke (Vector Format)

# Normalenschätzung in 3D Punktwolken

Ziel:

- Zusätzliche Oberflächeninformation durch Einbeziehung von lokalen Nachbarpunkten
- Grundlage für weiterführende Algorithmen
  - Segmentierung
  - Deskriptoren
  - Objekterkennung
  - Oberflächenmodellierung




# Normalenschätzung in 3D Punktwolken

- PCA-basierter Ansatz
- Erstelle die Kovarianzmatrix  $C$  der  $k$ -Punktnachbarschaft für jeden Punkt  $p$

$$C = \frac{1}{k} \sum_{i=1}^k (p_i - \bar{p}) \cdot (p_i - \bar{p})^T$$


$p_i$      $k$  Nachbarpunkte  
 $\bar{p}$     Mittelpunkt aller  $k$  Nachbarn

- Bestimme die Eigenwerte und Eigenvektoren von  $C$ 
  - Hauptkomponentenanalyse (Principle Component Analysis, PCA)
  - Eigenvektor zu kleinstem Eigenwert korrespondiert mit der Normalen




# Registrierung von Punktwolken

- **Registrierung:** Zusammenführen von Punktwolken, welche das gleiche Objekt aus unterschiedlichen Ansichten beschreibt
- Überführung in ein übergeordnetes Koordinatensystem (z.B. Weltkoordinatensystem)
- Extrinsische Kalibrierung der Kameras erforderlich



Punktwolken eines Raumes aus unterschiedlichen Perspektiven



Registrierte Punktwolke

# Iterative Closest Point

- **Iterative Closest Point** (ICP) ist ein gängiger Algorithmus für die Registrierung zweier Mengen  $A, B$  mit a priori unbekannter Zuordnung (Besl und McKay, 1992)
- Beispiel: Registrierung zweier 3D Punktwolken
  - Für jede Iteration  $k$  gilt:
    - Für jeden Punkt  $a_i$  aus  $A$  suche Punkt  $b_i$  aus  $B$ , der  $a_i$  am nächsten liegt
    - Berechne eine Transformation  $T_k$  so dass  $D_k$  minimal wird, z.B. mit [Horn, 1987]:

$$D_k = \sum_i \|a_i - T_k \cdot b_i\|^2$$


- $D_k$  Kombiniert Translation und Rotation
- Wende Transformation  $T_k$  auf alle Punkte aus  $B$  an (Update)
- Abbruchkriterien:
  - Schwellwert für  $D_{k-1} - D_k$
  - Maximale Anzahl an Iterationen erreicht

# Iterative Closest Point II

- Minimiert die „Distanz“ zwischen zwei Punktwolken
- Sehr gut geeignet für die Rekonstruktion in 2D und 3D
- Vorteile
  - Algorithmus für Punkte, Normalenvektoren und andere Darstellungsformen anwendbar
  - Nur einfache mathematische Operationen notwendig
  - Schnelles Registrierungsergebnis
- Nachteile
  - Symmetrische Objekte können nicht ohne weiteres registriert werden
  - Konvergenz in ein lokales Minimum möglich
  - Überlappung der Punktwolken erforderlich



# Iterative Closest Point III



ICP iterations = 1  
White: Original point cloud  
Red: ICP aligned point cloud



# RANSAC (Random Sample Consensus)

- **RANSAC** ist eine **iterative Methode** zur Schätzung von Modellparametern aus Datenpunkten
- RANSAC ist eine **nicht-deterministischer** Algorithmus
- Robust gegenüber Ausreißern und fehlenden Datenpunkten
- Anwendung in der Bildverarbeitung
  - Schätzung von Linien in 2D Bildern
  - Schätzung von Ebenen und anderen Primitiven in 3D Punktwolken


# RANSAC (Random Sample Consensus)

## ■ Der RANSAC Algorithmus:

1. Wähle zufällig die minimale Anzahl an Punkten aus, die nötig ist um die Modellparameter zu berechnen
  - 2 Punkte für Linien in 2D
  - 3 Punkte für Ebenen in 3D
2. Schätze ein Modell aus dem ausgewählten Datensatz
3. Bewertung der Modellschätzung:  
Berechne die Teilmenge der Datenpunkte (*Inliers*), deren Abstand zum Modell kleiner ist als ein vordefinierter Schwellwert
4. Wiederhole 1-3 bis das Modell mit den meisten Inliers gefunden wird

# RANSAC (Random Sample Consensus)


- Beispiel:
  - Line fitting in 2D Datenpunkte



- RANSAC Algorithmus:
  1. Wähle zufällig die minimale Anzahl an Punkten aus, die nötig ist um die Modellparameter zu berechnen
  2. Schätzung des Modell aus dem ausgewählten Datensatz
  3. Bewertung der Modellschätzung
  4. Wiederhole 1-3 bis das Modell mit den meisten Inliers gefunden wird

# RANSAC (Random Sample Consensus)

- Beispiel:
  - Line fitting in 2D Datenpunkte




- RANSAC Algorithmus:
  1. **Wähle zufällig die minimale Anzahl an Punkten aus, die nötig ist um die Modellparameter zu berechnen**
  2. Schätzung des Modell aus dem ausgewählten Datensatz
  3. Bewertung der Modellschätzung
  4. Wiederhole 1-3 bis das Modell mit den meisten Inliers gefunden wird

# RANSAC (Random Sample Consensus)

## ■ Beispiel:

- Line fitting in 2D Datenpunkte

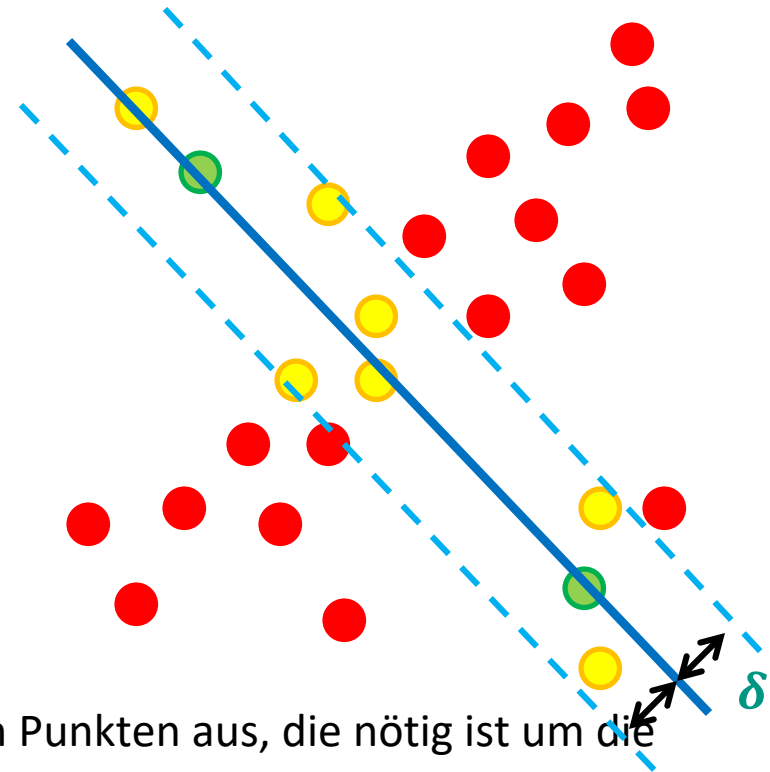


## ■ RANSAC Algorithmus:

1. Wähle zufällig die minimale Anzahl an Punkten aus, die nötig ist um die Modellparameter zu berechnen
2. **Schätzung des Modell aus dem ausgewählten Datensatz**
3. Bewertung der Modellschätzung
4. Wiederhole 1-3 bis das Modell mit den meisten Inliers gefunden wird

# RANSAC (Random Sample Consensus)

- Beispiel:
  - Line fitting in 2D Datenpunkte




- RANSAC Algorithmus:
  1. Wähle zufällig die minimale Anzahl an Punkten aus, die nötig ist um die Modellparameter zu berechnen
  2. Schätzung des Modell aus dem ausgewählten Datensatz
  - 3. Bewertung der Modellschätzung**
  4. Wiederhole 1-3 bis das Modell mit den meisten Inliers gefunden wird

# RANSAC (Random Sample Consensus)

- Beispiel:
  - Line fitting in 2D Datenpunkte

Inlier Anzahl = 9

Outlier Anzahl = 16




- RANSAC Algorithmus:
  1. Wähle zufällig die minimale Anzahl an Punkten aus, die nötig ist um die Modellparameter zu berechnen
  2. Schätzung des Modell aus dem ausgewählten Datensatz
  - 3. Bewertung der Modellschätzung**
  4. Wiederhole 1-3 bis das Modell mit den meisten Inliers gefunden wird

# RANSAC (Random Sample Consensus)

- Beispiel:
  - Line fitting in 2D Datenpunkte

Inlier Anzahl = 17

Outlier Anzahl = 8



- RANSAC Algorithmus:
  1. Wähle zufällig die minimale Anzahl an Punkten aus, die nötig ist um die Modellparameter zu berechnen
  2. Schätzung des Modell aus dem ausgewählten Datensatz
  3. Bewertung der Modellschätzung
  4. **Wiederhole 1-3 bis das Modell mit den meisten Inliers gefunden wird**




# RANSAC (Random Sample Consensus)

Die voraussichtliche **Anzahl an Iterationen**  $k$  damit der Algorithmus mit der **Wahrscheinlichkeit**  $P$  bei  $n$  Punkten erfolgreich terminiert, kann wie folgt berechnet werden:

- Wahrscheinlichkeit für einen Inlier:  $P(\text{inlier}) = w$   
( $w$  = Anzahl der Inlier/Gesamtzahl der Samples)
- Wahrscheinlichkeit ein Inlier-Modell zu fitten/ziehen:  
 $P(\text{subset with no outlier}) = w^n$
- Wahrscheinlichkeit ein Outlier-Modell zu ziehen:  
 $P(\text{subset with outliers}) = 1 - w^n$
- Wahrscheinlichkeit in  $k$  Iterationen ein Outlier-Modell zu ziehen:  
 $P(k \text{ subsets with outliers}) = (1 - w^n)^k$
- Wahrscheinlichkeit für einen erfolglosen Durchlauf:  $P(\text{fail}) = (1 - w^n)^k$
- Wahrscheinlichkeit für einen erfolgreichen Durchlauf:  $P(\text{success}) = 1 - (1 - w^n)^k$
- Voraussichtliche Anzahl an Iterationen:  $\Rightarrow k = \frac{\log(1 - P(\text{success}))}{\log(1 - w^n)}$

# RANSAC (Random Sample Consensus)

- RANSAC benötigt mehr Iterationen im Fall von vielen Outliern!



- Voraussichtliche Anzahl an Iterationen:  $\Rightarrow k = \frac{\log(1-P(\text{success}))}{\log(1-w^n)}$
- Minimale Sample Anzahl  $n$  muss vorher definiert sein!
- $P(\text{success})$  muss hoch angesetzt werden (d.h.  $\geq 95\%$ )

# RANSAC (Random Sample Consensus)

## ■ Vorteile:

- Simpel, allgemein und einfach zu implementieren
- Robuste Modellschätzung für Daten mit wenigen Ausreißern
- Vielseitig anwendbar

## ■ Nachteile:

- Nicht-deterministisch
- Viele Parameter
- Trade-off zwischen Genauigkeit und Laufzeit (benötigt viele Iterationen)
- Nicht anwendbar wenn das Verhältnis Inliers/Outliers zu klein ist

# Simultaneous Localization and Mapping (SLAM)

## ■ Das SLAM Problem:

Wie kann ein Roboter in einer unbekanntem Umgebung **navigieren** und dabei eine Karte von seiner Umgebung **erstellen** und auch **aktualisieren**?

## ■ SLAM bedeutet die Schätzung der aktuellen Roboterpose als auch der Karte der Umgebung **zur gleichen Zeit**.

## ■ SLAM wird benötigt

- um voll autonome Roboter zu bauen
- um in einer unbekanntem Umgebung zu überleben
- um zu wissen wo sich der Roboter gerade befindet
- um die Navigation ohne externe Positionsbestimmung (z.B. GPS) zu ermöglichen.

# Simultaneous Localization and Mapping (SLAM)




- Es entsteht ein Henne-Ei-Problem. Wir brauchen
  - eine Karte, um den Roboter zu **lokalisieren** (aber SLAM hat kein Vorwissen über die Umgebung)
  - und eine genaue Schätzung der Position, um eine **Karte** zu erstellen
- Begriffe:
  - **Lokalisierung**: Schätzen der Roboterposition bei gegebener Karte
  - **Kartierung**: Aus einer Menge von Positionen eine Karte ableiten
  - **SLAM**: Gleichzeitige Lokalisierung und Kartierung

# Simultaneous Localization and Mapping (SLAM)

- Lösung:  
Position von Kamera und Roboter während einer Bewegung verfolgen
- Deshalb braucht der Roboter **Features**, die er zuordnen und verfolgen kann
  - SLAM wählt Szenenfeatures als **Orientierungspunkte**
  - Visuelle Features: Punkte, Ecken, Kanten, Texturen, Oberflächen
  - Hinweis: Features müssen unterscheidbar und deskriptiv sein  
(Invariant gegenüber Standpunktwechsel)

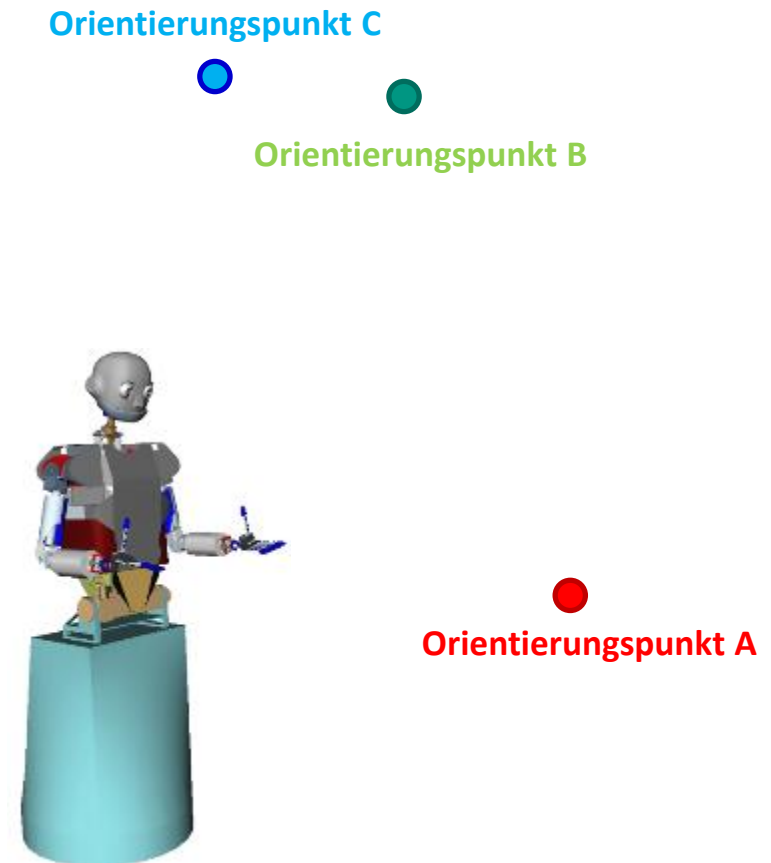
# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- Punktwolken
- **SLAM**
- Anwendungsbeispiel



# Simultaneous Localization and Mapping (SLAM)

- Wie funktioniert SLAM?
  - Interne Repräsentation für:
    - Position der Orientierungspunkte
    - Parameter der Kamera
  - In jedem Frame:
    - Vorhersage, wie viel sich der Roboter bewegt hat






# Simultaneous Localization and Mapping (SLAM)

## ■ Wie funktioniert SLAM?


- Interne Repräsentation für:
  - Position der Orientierungspunkte
  - Parameter der Kamera
  
- In jedem Frame:
  - Vorhersage, wie viel sich der Roboter bewegt hat
  - Neue Orientierungspunkte aufnehmen



# Simultaneous Localization and Mapping (SLAM)

## ■ Wie funktioniert SLAM?


- Interne Repräsentation für:
  - Position der Orientierungspunkte
  - Parameter der Kamera
- In jedem Frame:
  - Vorhersage, wie viel sich der Roboter bewegt hat
  - Neue Orientierungspunkte aufnehmen
  - Interne Repräsentation aktualisieren (Messungenauigkeiten beachten)



# Simultaneous Localization and Mapping (SLAM)

## ■ Wie funktioniert SLAM?


- Interne Repräsentation für:
  - Position der Orientierungspunkt
  - Parameter der Kamera
  
- In jedem Frame:
  - Vorhersage, wie viel sich der Roboter bewegt hat
  - Neue Orientierungspunkte aufnehmen
  - Interne Repräsentation aktualisieren (Messungenauigkeiten beachten)



# Simultaneous Localization and Mapping (SLAM)

## ■ Wie funktioniert SLAM?


- Interne Repräsentation für:
  - Position der Orientierungspunkt
  - Parameter der Kamera
  
- In jedem Frame:
  - Vorhersage, wie viel sich der Roboter bewegt hat
  - Neue Orientierungspunkte aufnehmen
  - Interne Repräsentation aktualisieren (Messungenauigkeiten beachten)



# Simultaneous Localization and Mapping (SLAM)

## ■ Wie funktioniert SLAM?


- Interne Repräsentation für:
  - Position der Orientierungspunkt
  - Parameter der Kamera
  
- In jedem Frame:
  - Vorhersage, wie viel sich der Roboter bewegt hat
  - Neue Orientierungspunkte aufnehmen
  - Interne Repräsentation aktualisieren (Messungenauigkeiten beachten)



# Simultaneous Localization and Mapping (SLAM)

## ■ Wie funktioniert SLAM?

- Interne Repräsentation für:
  - Position der Orientierungspunkte
  - Parameter der Kamera
  
- In jedem Frame:
  - Vorhersage, wie viel sich der Roboter bewegt hat
  - Neue Orientierungspunkte aufnehmen
  - Interne Repräsentation aktualisieren (Messungenauigkeiten beachten)

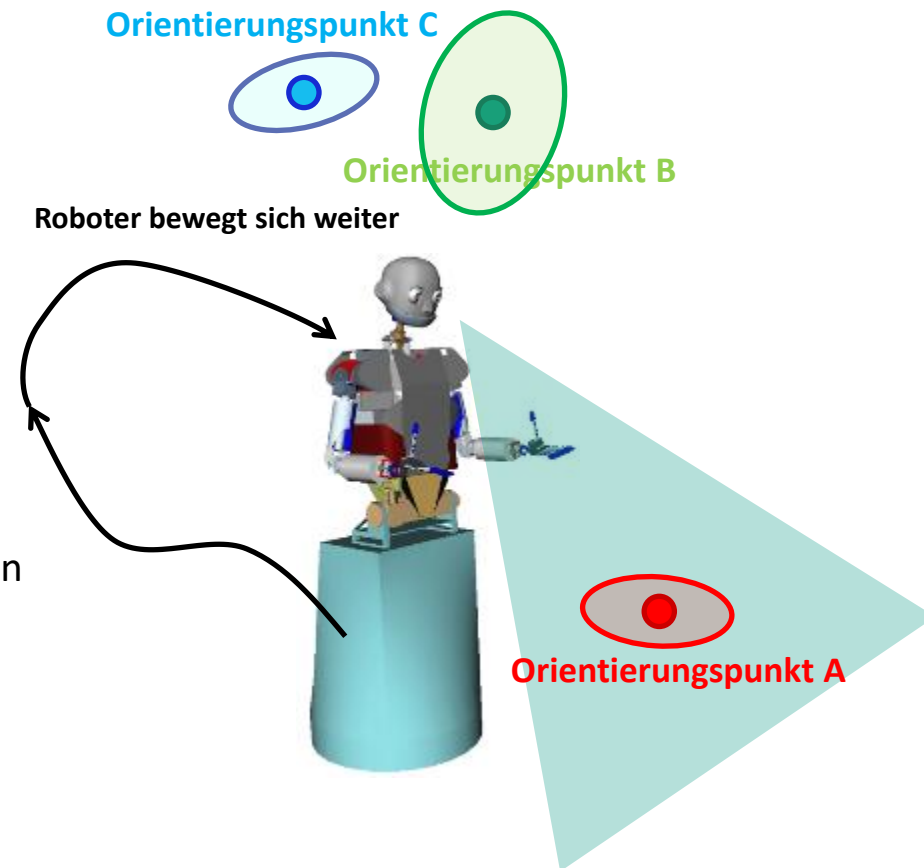


# Simultaneous Localization and Mapping (SLAM)

## ■ Wie funktioniert SLAM?





- Interne Repräsentation für:
  - Position der Orientierungspunkte
  - Parameter der Kamera
  
- In jedem Frame:
  - Vorhersage, wie viel sich der Roboter bewegt hat
  - Neue Orientierungspunkte aufnehmen
  - Interne Repräsentation aktualisieren (Messungenauigkeiten beachten)

Roboter sieht bekanntes Feature:  
Es kann eine Zuordnung stattfinden



# Inhalt

- Bildrepräsentation
- Kameramodell
- Filteroperationen
- Segmentierung
- Morphologische Operatoren
- Canny-Kantendetektor
- Tiefenkameras
- Visual Servoing
- Punktwolken
- SLAM
- **Anwendungsbeispiel**





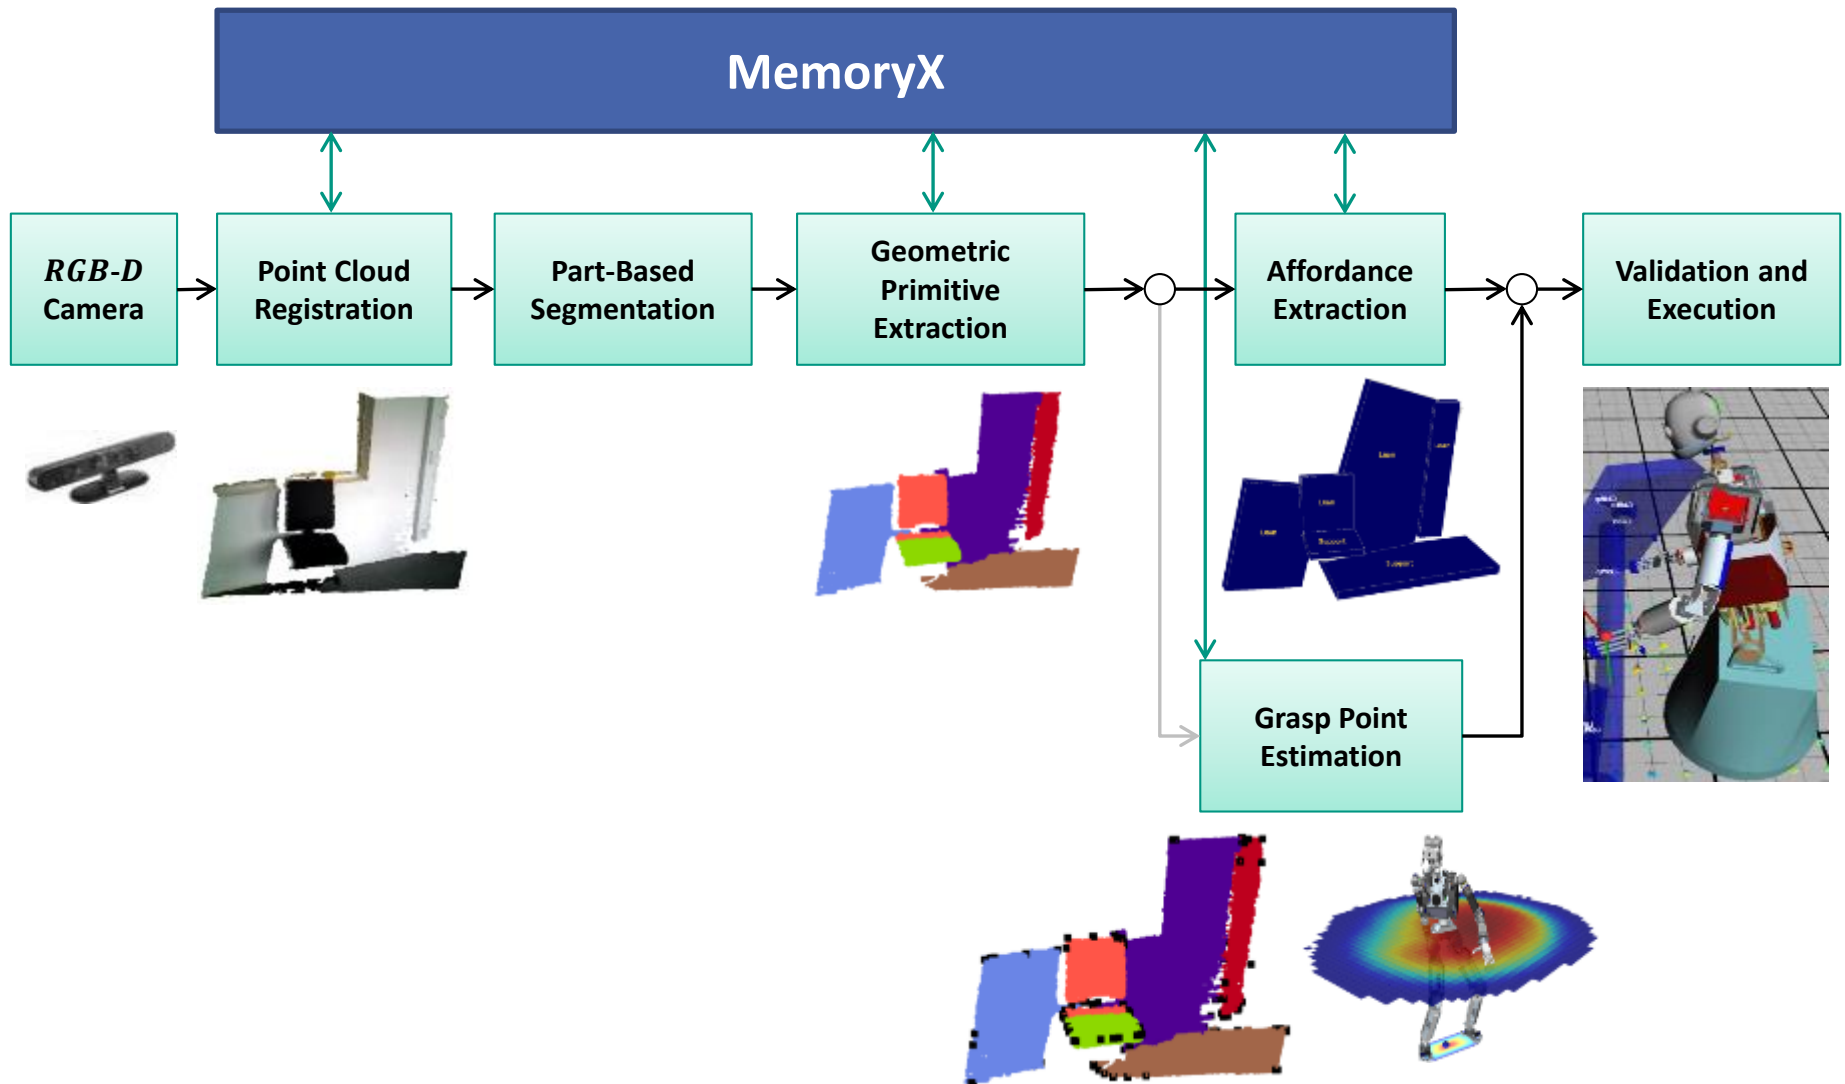
## Beispiel: Perceptual Pipeline

- SLAM
- RANSAC
  
- Integriert in das Roboter-Softwareframework ArmarX (späteres Kapitel)

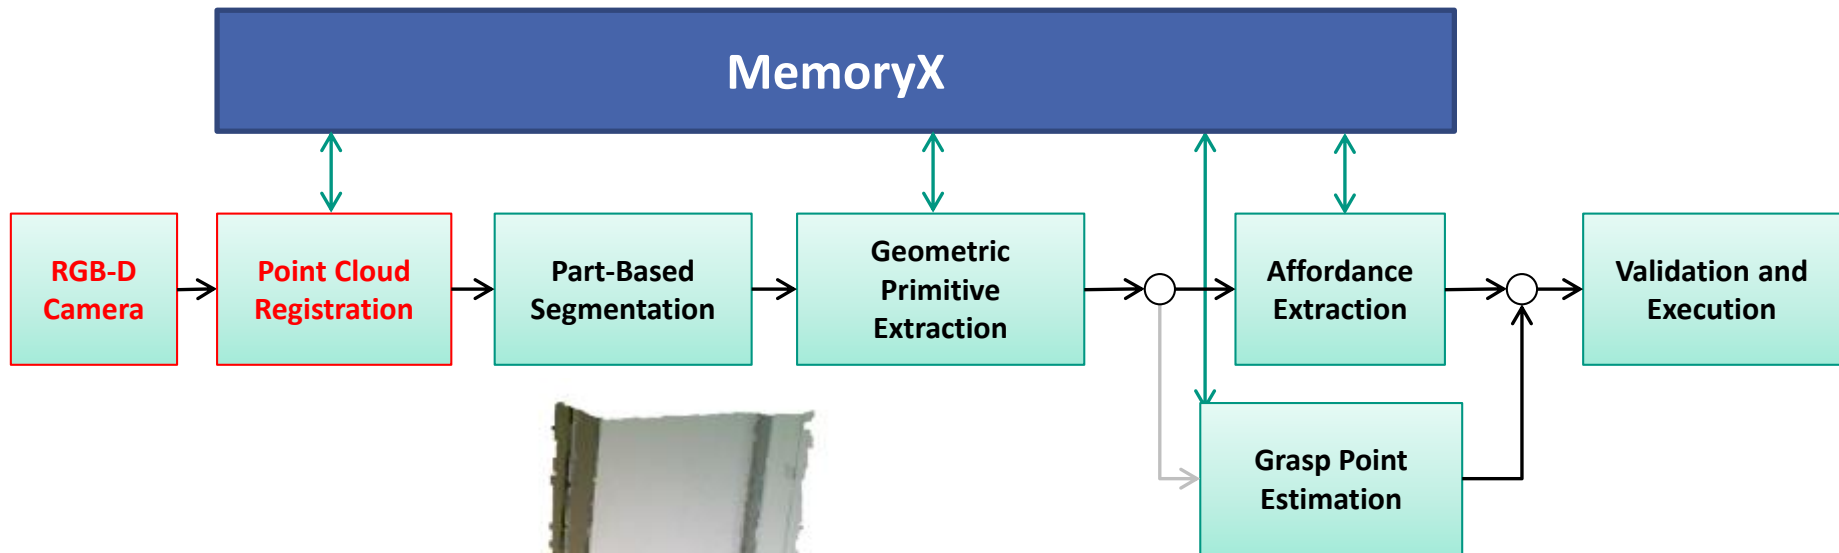
## Loco-Manipulation Affordances

Kaiser P., Grotz M. Aksoy E.E., Do M. Vahrenkamp N. Asfour T.,  
“Validation of Whole-Body Loco-Manipulation Affordances for Pushability and  
Liftability”, In IEEE-RAS International Conference on Humanoid Robots 2015.

# Loco-Manipulation Affordances



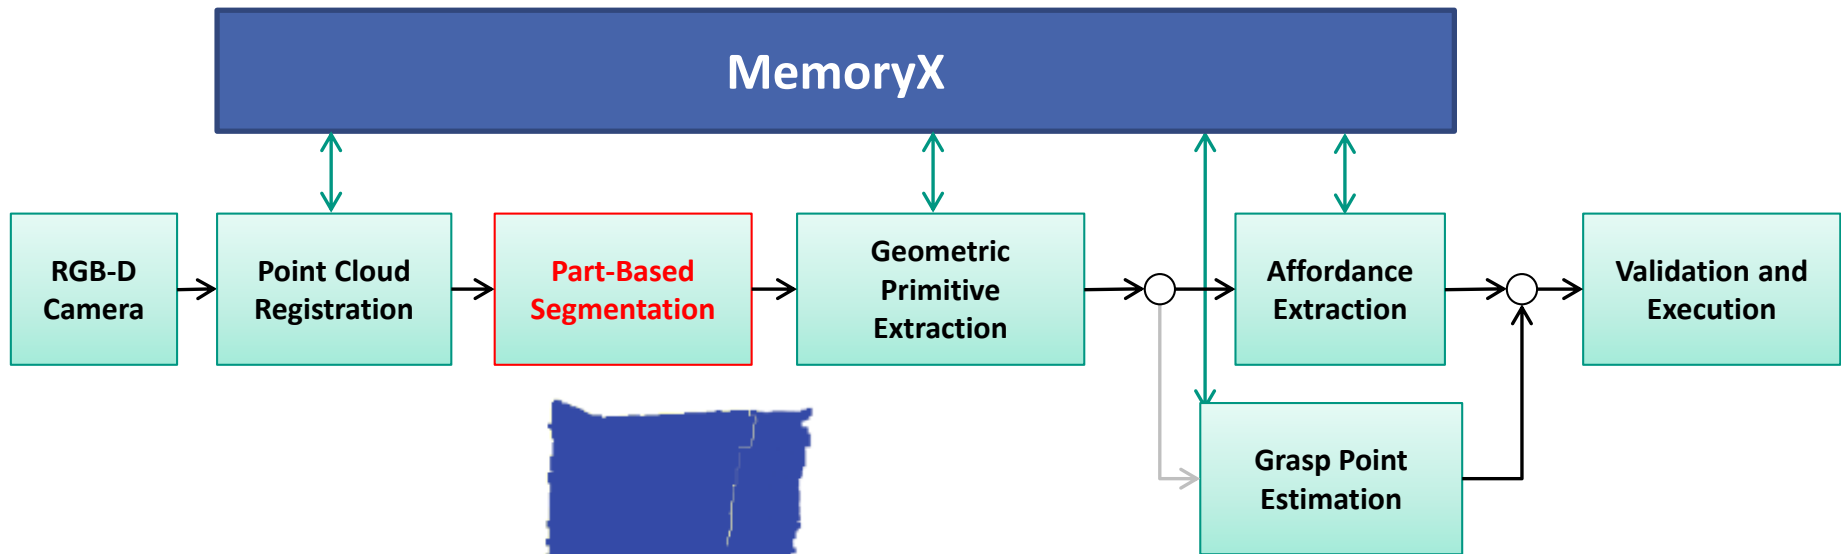
# Loco-Manipulation Affordances



- Daten aufgenommen mit der Asus Xtion Pro Kamera
- Registrierung der Kamerabilder mit der OpenSource Bibliothek Real Time Appearance Based Mapping (RTAB-Map).

**RTAB-Map:** M. Labbe and F. Michaud, "Online global loop closure detection for large-scale multi-session graph-based slam," in IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp. 2661–2666, IEEE, 2014.


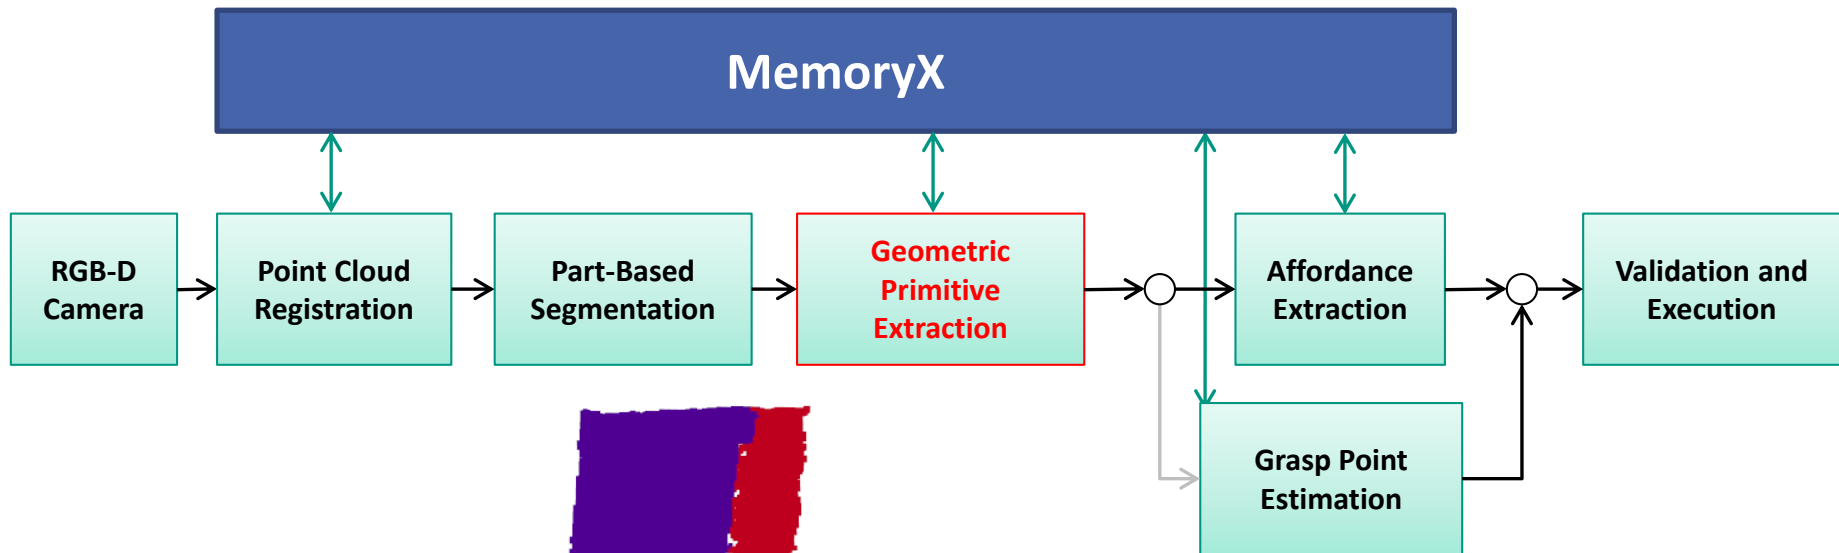
# Loco-Manipulation Affordances



- Tiefenbasierte Segmentierung: benötigt für Szenenerlegung
- Wir verwenden Locally Convex Connected Patches (LCCP) zur Segmentierung
- Vorteil: Einfach und schnell
- Nachteil: Untersegmentierung (z.B. Stuhl)

**Segmentation:** S. Stein, F. Wörgötter, M. Schoeler, J. Papon, and T. Kulvicius, "Convexity based object partitioning for robot applications," in International Conference on Robotics and Automation ICRA, June 2014.


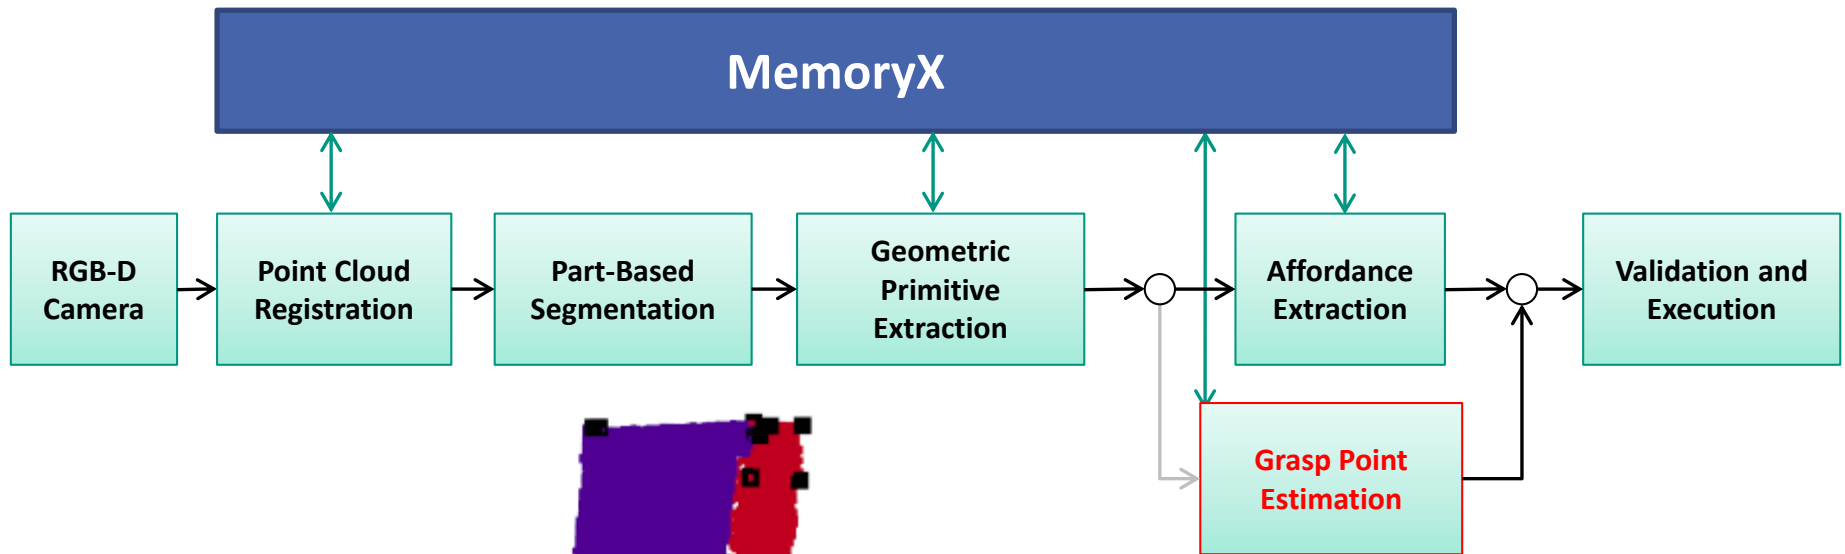
# Loco-Manipulation Affordances




- Fitting von geometrischen Modellen (z.B. Ebenen und Zylinder) an Segmente mit RANSAC
- Wegen Untersegmentierung werden Modelle iterativ an die verbleibenden Outliers gefittet (z.B. Stuhl)

PCL: R. B. Rusu and S. Cousins, "3d is here: Point cloud library (pcl)," in International Conference on Robotics and Automation, 2011.

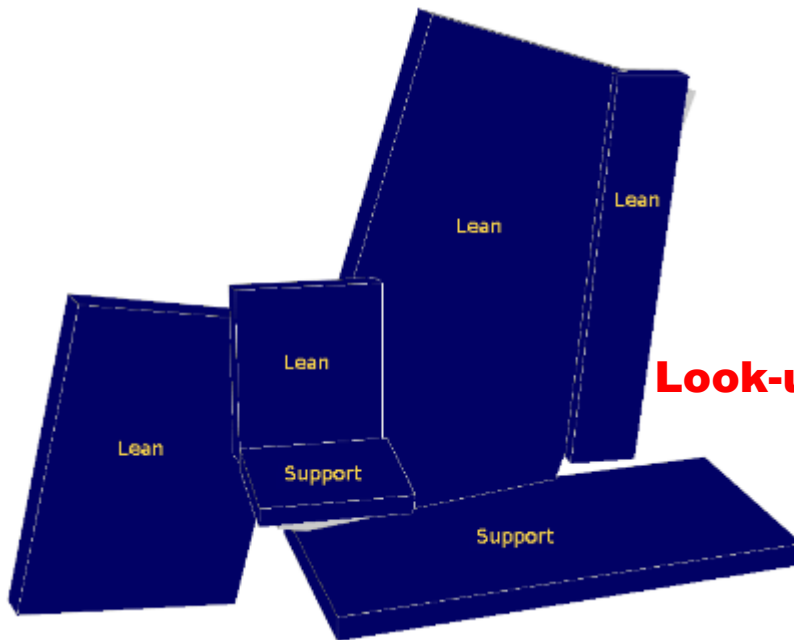
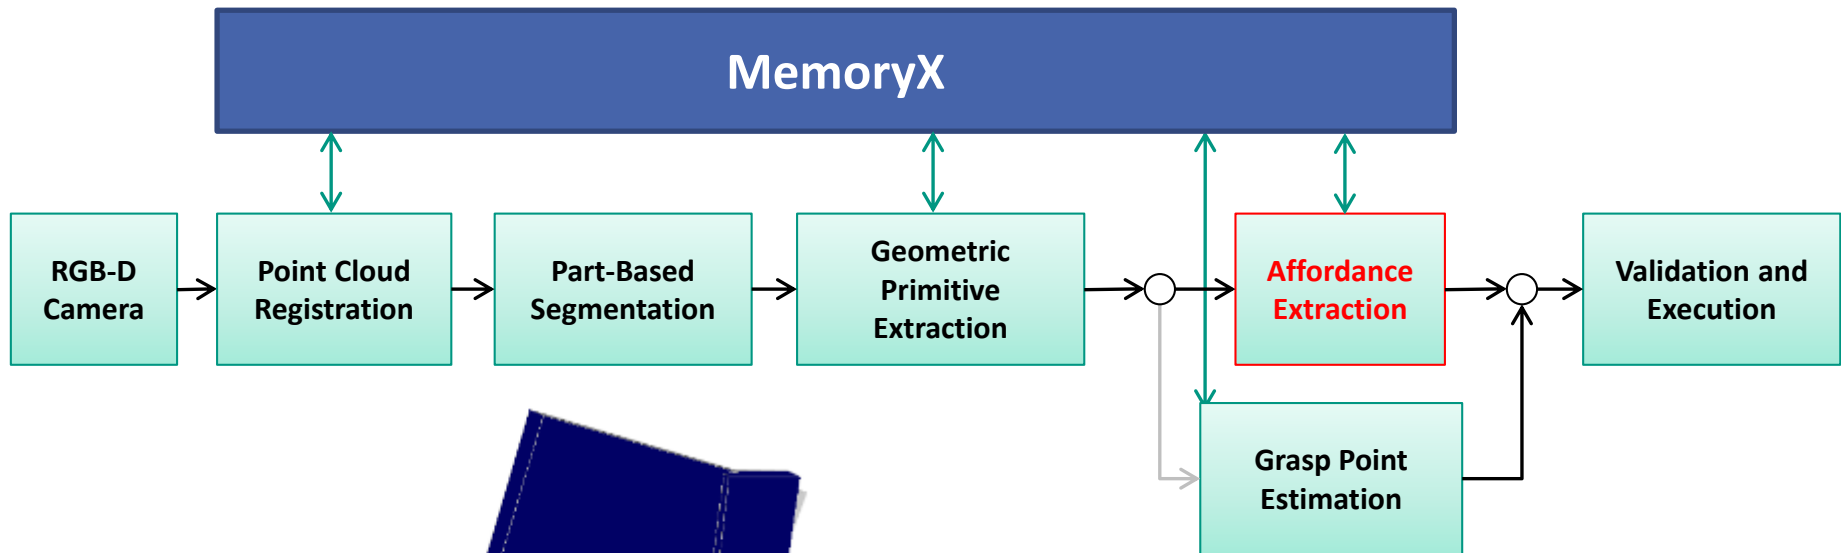
# Loco-Manipulation Affordances



- Berechne konvexe Hülle für die projizierten Inlier Punkte um *Grasp Points* zu schätzen. Vgl. Schwarzen Punkte am Stuhl.
- Invertierte Reachability Map um Punkte zu filtern.



# Loco-Manipulation Affordances



**Look-up Tabelle!**


| Affordance     | Shape       | Parameters                           | Conditions   | Valid. |
|----------------|-------------|--------------------------------------|--|--------|
| <b>Support</b> | Planar      | Normal $\mathbf{n}$<br>Area $a$      | $\mathbf{n} \uparrow \mathbf{z}_{world}$<br>$a \geq \lambda_1$             | (1a)   |
| <b>Lean</b>    | Planar      | Normal $\mathbf{n}$<br>Area $a$      | $\mathbf{n} \perp \mathbf{z}_{world}$<br>$a \geq \lambda_2$                | (1a)   |
| <b>Grasp</b>   | Planar      | Normal $\mathbf{n}$<br>Area $a$      | $a \in [\lambda_3, \lambda_4]$   | (3)    |
|                | Cylindrical | Radius $r$<br>Direction $\mathbf{d}$ | $r \in [\lambda_5, \lambda_6]$<br>$\ \mathbf{d}\  \leq \lambda_7$          |        |
|                | Spherical   | Radius $r$                           | $r \in [\lambda_8, \lambda_9]$   |        |
| <b>Hold</b>    | Cylindrical | Radius $r$<br>Direction $\mathbf{d}$ | $r \in [\lambda_{10}, \lambda_{11}]$<br>$\ \mathbf{d}\  \geq \lambda_{12}$ | (2a)   |
| <b>Push</b>    | Planar      | Normal $\mathbf{n}$<br>Area $a$      | $\mathbf{n} \perp \mathbf{z}_{world}$<br>$a \leq \lambda_{13}$             | (1b)   |

# Loco-Manipulation Affordances


Registered Point Clouds






Segmented Point Cloud



Primitive & Grasp Points

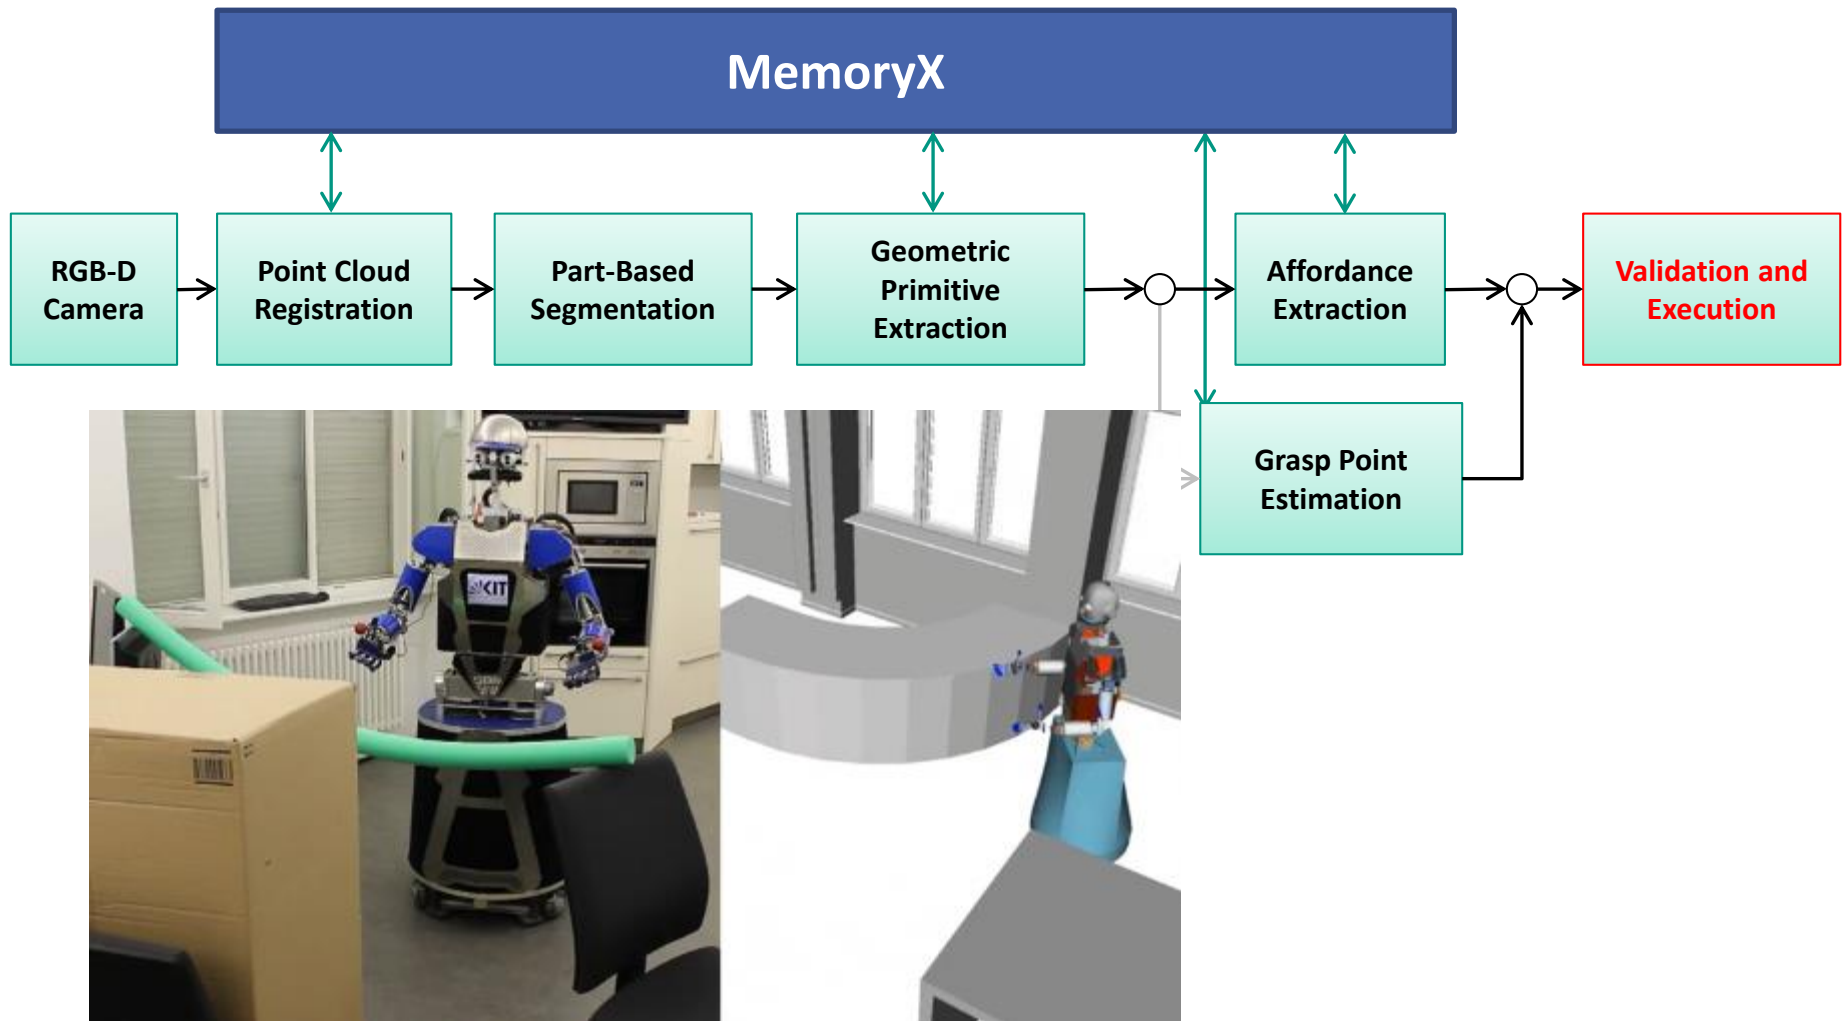


Affordances





# Loco-Manipulation Affordances



# Loco-Manipulation Affordances



## Validation of Whole-Body Loco-Manipulation Affordances for Pushability and Liftability

Peter Kaiser, Markus Grotz, Eren E. Aksoy, Martin Do, Nikolaus Vahrenkamp and Tamim Asfour

Institute for Anthropomatics and Robotics - High Performance Humanoid Technologies Lab (H2T)

KIT – University of the State of Baden-Wuerttemberg and National Laboratory of the Helmholtz Association

[www.kit.edu](http://www.kit.edu)

Kaiser P., Grotz M. Aksoy E.E., Do M. Vahrenkamp N. Asfour T., “Validation of Whole-Body Loco-Manipulation Affordances for Pushability and Liftability”, In IEEE-RAS International Conference on Humanoid Robots 2015.

# Englische Begriffe

| Deutsch                 | Englisch                |
|-------------------------|-------------------------|
| Farbnuance              | hue                     |
| Sättigung               | saturation              |
| Helligkeit              | intensity/value         |
| Hauptachse              | principal axis          |
| Hauptpunkt              | principal point         |
| Bildkoordinaten         | image coordinates       |
| Kamerakoordinatensystem | camera coordinates      |
| Weltkoordinatensystem   | world coordinate system |
| Schwellenwertverfahren  | thresholding            |
| Punktwolken             | point clouds            |
| Kartierung              | mapping                 |
| Orientierungspunkt      | landmark                |