

03-05-H  
-709.53

# Echtzeitbildverarbeitung (11)

Prof. Dr. Udo Frese

Auffrischung Stochastik  
Quadratische Ausgleichsrechnung  
Downhill Simplex Algorithmus

# Was bisher geschah

## ▶ Geometrische Rekonstruktion

- ▶ Kalibrierte Kamera ist ein Winkelmessgerät, eine Länge benötigt
- ▶ Meist ist es so, wie die Zahl der Freiheitsgrade suggeriert.
- ▶ Fluchtpunkt von parallelen Geraden hängt nur von Richtung ab.
- ▶ Zwei Winkel zu Landmarken beschränkt die Position auf einen Kreis.

## ▶ Kameragleichung in 3D (Parameter DOF)

- ▶ Transformation in Kamerakoordinaten  $C2W^{-1}$  (6DOF)

- ▶ Perspektive  $p$  (0 DOF)

- ▶ Verzerrung  $d_{\kappa}$  (üblich: 0/1DOF)

- ▶ Skalierung/Offset (1/3DOF)

$$\begin{pmatrix} x_I \\ y_I \end{pmatrix} = \begin{pmatrix} x_{center} \\ y_{center} \end{pmatrix} + f_{eff} \cdot d_{\kappa} \left( p \left( C2W^{-1} \cdot p_W \right) \right)$$

## ▶ RANSAC

- ▶ finde passende Zuordnungen aus einer Menge von Zuordnungen
- ▶ generiere Hypothese aus zufällig gezogenen Zuordnungen
- ▶ zähle, wie viele Zuordnungen dazu passen

# Auffrischung Stochastik

# Auffrischung Stochastik

- ▶ **Zufallsexperiment: Ein Vorgang der einen nicht vorher-sagbaren beobachtbaren Ausgang hat. Hier pragmatisch aufgefasst. Z.B. das Werfen zweier Würfels.**
- ▶ **Zufallsvariablen  $X, Y$  sind Größen, die von dem Ausgang eines Zufallsexperimentes abhängen. Z.B. Augensumme.**
- ▶  **$p(X=x)$  ist die Wahrscheinlichkeit(-sdichte) dafür, dass die Zufallsvariable  $X$ , den Wert  $x$  hat. Es ist also eine Funktion von  $x$ .**
- ▶ **Wichtige Unterscheidung:  $X$  ist eine Zufallsvariable, also eine Größe, die vom Zufallsexperiment abhängt.  $x$  ist einfach nur eine Zahl. So wie  $p(X=0)$ ,  $p(X=7)$**



# Auffrischung Stochastik

- ▶  $p(X=x, Y=y)$  ist die Wahrscheinlichkeit(-sdichte), dass  $X$  den Wert  $x$  hat und  $Y$  den Wert  $y$  hat.
- ▶  $p(X=x|Y=y) = p(X=x, Y=y) / p(Y=y)$  ist die Wahrscheinlichkeit(-sdichte), dass  $X$  den Wert  $x$  hat, wenn  $Y$  schon den Wert  $y$  hat.
- ▶ Zwei Zufallsvariablen sind stochastisch unabhängig, wenn  $p(X=x, Y=y) = p(X=x) p(Y=y)$
- ▶ Kurzschreibweise  $p(x)$  statt  $p(X=x)$ , etc.
- ▶ Schreibweise: Bei kontinuierlichen Zufallsexperimenten  $p(\dots)$  für Wahrscheinlichkeitsdichten, bei diskreten  $P()$  für Wahrscheinlichkeiten.



# Auffrischung Stochastik

- ▶ **Zufallsexperiment:** Werfen zweier Würfel (einer weiß, einer rot)
- ▶ **Zufallsvariable:** X Augen des roten Würfel, Y Augen des weißen Würfel,  $Z=X+Y$ : Augensumme

Frage an das Auditorium:  
Welche Wahrscheinlichkeiten haben die verschiedenen Ereignisse?

$P(X=x, Y=y)=$

	$P(X=_)$	$P(Y=_)$	$P(Z=_)$	$P(Z=_   X=3)$	$P(Z=_   Y=4)$	$P(Z=_   X=4, Y=3)$
1						
2						
3						
4						
5						
6						
7						
8						
9						
10						
11						
12						

# Auffrischung Stochastik

- ▶ **Zufallsexperiment:** Werfen zweier Würfel (einer weiß, einer rot)
- ▶ **Zufallsvariable:** X Augen des roten Würfel, Y Augen des weißen Würfel,  $Z=X+Y$ : Augensumme

	$P(X=_)$	$P(Y=_)$	$P(Z=_)$	$P(Z=_   X=3)$	$P(Z=_   Y=4)$	$P(Z=_   X=4, y=3)$
1	1/6	1/6	0	0	0	0
2	1/6	1/6	1/36	0	0	0
3	1/6	1/6	2/36	0	0	0
4	1/6	1/6	3/36	1/6	0	0
5	1/6	1/6	4/36	1/6	1/6	0
6	1/6	1/6	5/36	1/6	1/6	0
7	0	0	6/36	1/6	1/6	1
8	0	0	5/36	1/6	1/6	0
9	0	0	4/36	1/6	1/6	0
10	0	0	3/36	0	1/6	0
11	0	0	2/36	0	0	0
12	0	0	1/36	0	0	0

**$P(X=x, Y=y)=1/36,$   
für alle  
 $x,y \in [1..6]$   
sonst 0**

# Quadratische Ausgleichsrechnung

# Quadratische Ausgleichsrechnung

## Aufgabe

- ▶ **bestimme Parameter eines Messmodells so, dass Vorhersagen möglichst gut mit Messungen übereinstimmen.**
- ▶ **Ziel: Mehr Messungen sollten die Genauigkeit verbessern (Ausgleichsrechnung), z.B. gegenüber RANSAC**
- ▶ **Anwendung Kalibrierung:**
  - ▶ bestimme Kamerapose  $C2W$ , Verzerrung  $\kappa$  und Brennweite  $f_{eff}$  so, dass Projektionen bekannter Punkte möglichst gut mit Bildpunkten übereinstimmen.
- ▶ **Anwendung Kamera / Objektlage:**
  - ▶ wie oben, aber  $\kappa$  und  $f$  sind fest.
- ▶ **Anwendung 3D Rekonstruktion :**
  - ▶ bestimme Kameraposen  $C2W$  und Punkte, so dass deren Projektion möglichst gut mit Bildpunkten übereinstimmen.
  - ▶ heißt auch Simultaneous Localization and Mapping (SLAM), Structure from Motion (SfM) oder Bundle Adjustment

# Quadratische Ausgleichsrechnung

## Praxis

- ▶ die Theorie ist hilfreich, aber nicht ganz leicht zu verstehen.
- ▶ deshalb zuerst: Was rechnen wir am Ende praktisch?

$$\hat{x} = \arg \min_x \sum_i \frac{(z_i - f_i(x))^2}{\sigma_i^2}$$

- ▶ wahrer Parameter  $X$  gesucht
- ▶ Messungen  $z_i$
- ▶ Messfunktion(-en)  $f_i$ , d.h. „wenn die Parameter  $x$  wären, müssten wir eigentlich  $Z_i=f_i(x)$  messen“
- ▶  $\sigma_i$  Unsicherheit der Messung  $Z_i$
- ▶  $\hat{x}$  ist Schätzung für  $X$
- ▶ Frage an das Autitorium: Können Ihr die Formel in Worte fassen?

# Quadratische Ausgleichsrechnung

## Praxis

▶ wahre Parameter  $X$ , gesucht

▶  $\hat{x}$  Schätzung für  $X$

▶ Messungen  $Z_i$

▶ Messfunktion(-en)  $f_i$ , d.h. „wenn der Zustand  $x$  wäre, müssten wir eigentlich  $Z_i=f_i(x)$  messen“

▶  $\sigma_i$  Unsicherheit der Messung  $Z_i$

▶ Formel in Worten

▶ Klammer ist Differenz zwischen, was wir bei Parameter  $x$  hätten messen sollen und was wir gemessen haben.

▶ Division durch  $\sigma_i^2$  macht die Differenz relativ zur Ungenauigkeit des Sensors.

▶ dadurch Maß für Plausibilität von  $x$  unter der Messung  $Z_i$ .

▶ Summe ist Gesamtplausibilität von  $x$  unter allen Messungen.

▶ wir suchen den plausibelsten Zustand.

$$\hat{x} = \arg \min_x \sum_i \frac{(z_i - f_i(x))^2}{\sigma_i^2}$$

# Quadratische Ausgleichsrechnung

## Ansatz

- ▶ **Modelliere Messvorgang als Zufallsexperiment, bei dem auf den „wahren“ Messwert der sich aus den „wahren“ Parametern ergibt eine zufällige Störung addiert wird. Frage dann nach den *wahrscheinlichsten* Parametern gegeben die Messungen.**

$$Z_i = f_i(X) + N_i$$

- ▶ **wahre Parameter  $X$ , Messungen  $Z_i$ , Messfunktion(-en)  $f_i$ , Störung  $N_i$**

# Quadratische Ausgleichsrechnung

## Herleitung

$$Z_i = f_i(X) + N_i$$

- ▶ **bekannt:  $Z_i=z_i, f_i$       Unbekannt:  $X, N_i$**
- ▶ **verschiedene  $f_i$  für verschiedene Messwerte möglich.**
  - ▶ verschiedene Teile einer Messung, z.B. X- und Y- Koordinate eines Bildpunktes
  - ▶ verschiedene Sensoren, z.B. Winkelpeilung und Radarentfernung
  - ▶ abhängig von Parameter  $f_i(X) = f(p_i, X)$ , z.B. Messung von Bildpunkten verschiedener Raumpunkte  $p_i$ .
- ▶ **Annahme: Störungen (Messungen) stochastisch unabhängig.**

# Quadratische Ausgleichsrechnung

## Herleitung

- ▶ **Gesucht:**  $\arg \max_x p(X=x|Z=z)$ ,
- ▶ **also der Parametersatz, mit der höchsten Wahrscheinlichkeit unter der Bedingung dass das gemessen wurde, was gemessen wurde.**
- ▶ **Berechnung über Bayes Theorem:**

$$p(X = x|Z = z)p(Z = z) = p(X = x, Z = z) = p(Z = z|X = x)p(X = x)$$

**Wahrscheinlichkeit,  
dass X den Wert x hat,  
gegeben, dass Z den  
Wert z hat**

**Wahrscheinlichkeit,  
dass Z den Wert z hat**

**Wahrscheinlichkeit,  
dass X den Wert x  
hat und dass Z den  
Wert z hat**

# Quadratische Ausgleichsrechnung

**A-posteriori  
Wahrscheinlichkeit**

$$\arg \max_x p(X = x | Z = z) = \arg \max_x \frac{p(Z = z | X = x)p(X = x)}{p(Z = z)}$$

$$= \arg \max_x p(Z = z | X = x)p(X = x) = \arg \max_x p(Z = z | X = x)$$

**Keine a-priori  
Info**

**P(Z=z)  
ist gleich  
für alle x**

**Wie wahrscheinlich ist es, Z=z zu messen,  
wenn X=x wäre? (likelihood von x)**

**Wie wahr-  
scheinlich ist x  
grundsätzlich?**

# Quadratische Ausgleichsrechnung

$$\begin{aligned}\arg \max_x p(Z = z | X = x) &= \arg \max_x p(f(X) + N = z | X = x) \\ &= \arg \max_x p(N = z - f(X) | X = x) = \arg \max_x p(N = z - f(x))\end{aligned}$$

▶ **Anschaulich:**

- ▶ für ein hypothetisches  $x$  wissen wir, was bei der Messung hätte herauskommen sollen, nämlich  $f(x)$ .
- ▶ wir wissen, was herausgekommen ist, nämlich  $Z=z$ .
- ▶ wir kennen den Meßfehler:  $z - f(x)$ .
- ▶ wie wahrscheinlich ist solch ein Meßfehler?

▶ **Messungen stochastisch unabhängig:**

$$= \arg \max_x p(N_i = z_i - f_i(x) \forall i) = \arg \max_x \prod_i p(N_i = z_i - f_i(x))$$

# Quadratische Ausgleichsrechnung

- ▶ Modell des Meßrauschens:
- ▶  $n_i$  hat Gaußverteilung mit Mittelwert  $\mu_i=0$  und Standardabweichung  $\sigma_i$ .

$$p(N_i = n_i) = \frac{1}{\sigma_i \sqrt{2\pi}} e^{-\frac{(n_i - \mu_i)^2}{2\sigma_i^2}}$$

$$= \arg \max_x \prod_i e^{-\frac{(z_i - f_i(x))^2}{2\sigma_i^2}} = \arg \min_x \sum_i \frac{(z_i - f_i(x))^2}{\sigma_i^2}$$



# Downhill Simplex Algorithmus


# Downhill Simplex Algorithmus

## Aufgabe

- ▶ **Finde Minimum einer Funktion**
- ▶ **für allgemeine Funktionen**
  - ▶ vom Startwert, schrittweise abwärts, bis es nicht mehr weitergeht.
  - ▶ Problem: vernünftiger Startwert nötig.
  - ▶ Problem: lokale Minima.
- ▶ **Vorteil: einfach, ohne Ableitungen.**
- ▶ **Quelle: Press, Teukolsky, Vetterling, Flannery, Numerical Recipes in C, Chapter, Chapter 10.4 (sehr gut für praktische Numerik)**
- ▶ **Nicht verwechseln mit Simplex aus Operations Research.**


# Downhill Simplex Algorithmus

- ▶ Frage an das Auditorium:  
Rechts sieht man Linien gleicher Werte für  $x^2+y^2-1.5xy$ .  
Was passiert, wenn man immer abwechselnd in x und y Richtung jeweils bis zum Minimum in dieser Richtung absteigt?



# Downhill Simplex Algorithmus


- ▶ **treppenförmiges Absteigen durch das langes, flache Tal.**
  - ▶ sehr ineffizient.
  - ▶ häufiges Phänomen
- ▶ **Gegenmassnahme:**
  - ▶ Minimierer soll sich Richtung des Tals anpassen.
  - ▶  $\Rightarrow$  Zustand des Minimierers ist mehr als nur einen Punkt.



# Downhill Simplex Algorithmus

## Simplex als Minimierzustand

- ▶  $n$  Parameter (7 bzw. 8 bei Kalibrierung).
- ▶ **Zustand des Minimierers ist ein Simplex im Parameterraum  $\mathbb{R}^n$ :**
  - ▶ konvexe Hülle aus  $n+1$  Vektoren.
  - ▶ kleinste Anzahl Vektoren, die alle Dimensionen des Raums aufspannen.
  - ▶ 1D: Interval, 2D: Dreieck, 3D: Tetraeder, ...
- ▶ **Simplex passt sich „wie eine Amöbe“ dem Tal an.**
- ▶ **vier Operationen: reflection, expansion, contraction, multiple contraction**
- ▶ **Versuch, den Parametervektor mit höchstem Funktionswert ( $p_n$ ) zu beseitigen, d.h. kleiner als den zweithöchsten zu machen.**



# Ein Schritt im Downhill Simplex

$$p^{neu} = \frac{1-\lambda}{n} \sum_{i=0}^{n-1} p_i + \lambda p_n$$

## ▶ reflection:

- ▶ schlechtesten Parametervektor ( $p_n$ ) über Schwerpunkt der anderen ( $\lambda=-1$ ) spiegeln.
- ▶ wenn besser, ersetzen.

## ▶ expansion: wenn besser als bester

- ▶  $\lambda=2$  auf *neuem*  $p_n$  probieren
- ▶ falls wieder besser ersetzen
- ▶ nicht  $\lambda=-2$ , weil schon gespiegelt






## ▶ contraction: wenn schlechter als zweitschlechtester

- ▶  $\lambda=1/2$  probieren.

## ▶ multiple contraction: wenn schlechter als alter schlechtester


- ▶ jeden Parametervektor durch die Mitte zum Besten ersetzen.

$$p_i^{neu} = \frac{p_i + p_0}{2} \quad \forall i = 1..n$$



# Downhill Simplex Algorithmus


$$p^{neu} = \frac{1-\lambda}{n} \sum_{i=0}^{n-1} p_i + \lambda p_n = (1-\lambda) \underbrace{\left( \frac{1}{n} \sum_{i=0}^{n-1} p_i \right)}_{\bar{p}} + \lambda p_n = (1-\lambda)\bar{p} + \lambda p_n$$




# Downhill Simplex Algorithmus

Analogie:


▶ Weiterfahren




▶ Gas geben



▶ Bremsen




▶ Vollbremsung



# Downhill Simplex Algorithmus


Nelder-Mead Simplex search over Himmelblau function



Quelle: wikipedia

# Downhill Simplex Algorithmus

Nelder-Mead Simplex search over Banana Function



Quelle: wikipedia

```

downhillSimplexStep () { //p Liste von Parametervektoren, Fehler in .error
  renormalize rotation representation // speziell für Drehungen
  sort p by ascending .error value
  if (p[n].error-p[0].error<tolerance) {
    if (p[0].error<lastRestart) {
      lastRestart = p[0].error;
      restart();
    }
    else return true; // simplex converged
  }
  compute pNew with  $\lambda=-1$  from p[n], evaluate pNew.error // reflection
  if (pNew.error<=p[n].error) p[n] = pNew;
  if (pNew.error<=p[0].error) { // gut!
    compute pNew with  $\lambda=2$  from p[n], evaluate pNew.error // and expansion
    if (pNew.error<=p[n].error) p[n] = pNew; // besser!
  }
  else if (pNew.error>=p[n-1].error) { // mäßig
    compute pNew with  $\lambda=0.5$  from p[n], evaluate pNew.error // contraction
    if (pNew.error<=p[n].error) p[n] = pNew;
    else { // besch...
      for (int i=1;i<=n;i++) // multiple contraction
        compute p[i] as (p[i]+p[0])/2, evaluate p[i].error
    }
  }
  return false; // weitere Iterationen nötig
}

```

# Downhill Simplex Algorithmus

## Initialisierung, restart und Renormalisierung

- ▶ **Man benötigt einen Startparametervektor  $p_{\text{start}}$** 
  - ▶ Startwert von Hand wählen (oft mühsam).
  - ▶ RANSAC (gewählte Lösung mit meisten passenden Daten)
  - ▶ bei restart besten Parametervektor  $p[0]$  als  $p_{\text{start}}$  verwenden.
- ▶ **Startsimplex**
  - ▶  $p_{\text{start}}$
  - ▶  $n$  mal  $p_{\text{start}}$  in je einer Komponente um  $\varepsilon$  erhöht.
  - ▶  $\varepsilon$  lieber klein wählen
- ▶ **Renormalisierung**
  - ▶ wenn Orientierungen Teil der Parameter sind
  - ▶ su.

# Zusammenfassung

## ▶ Quadratische Ausgleichsrechnung

- ▶ Berechnung der wahrscheinlichsten Parameter

$x = \operatorname{argmax}_x P(X=x|Z=z)$  als  $= \operatorname{argmax}_x P(Z=z | X=x)$ .

- ▶ „Die wahrscheinlichsten Parameter, gegeben, dass ich gesehen habe, was ich gesehen habe sind die, bei denen es am wahrscheinlichsten ist, dass zu sehen, was ich gesehen habe.“

- ▶ Gauß'sches Messrauschen führt zu quadratischer Minimierung.

$$\hat{x} = \operatorname{arg min}_x \sum_i \frac{(z_i - f_i(x))^2}{\sigma_i^2}$$

## ▶ Downhill Simplex Algorithmus

- ▶ Minimiert allgemeine Funktionen, einfach, ableitungsfrei aber langsam.
- ▶ Zustand durch Simplex von  $n+1$  Parametervektoren.
- ▶ vier Operationen: reflection, expansion, contraction, multiple-contraction