

# **Implementierung von Superresolution-Verfahren**

## **Studienarbeit im Studiengang Computervisualistik**

vorgelegt von

Leif Baierl

Betreuer: Dipl.-Inf. Detlev Droege, Institut für Computervisualistik, Fachbereich Informatik  
Erstgutachter: Dipl.-Inf. Detlev Droege, Institut für Computervisualistik, Fachbereich Informatik  
Zweitgutachter:

Koblenz, im Mai 2007



## Erklärung

Ich versichere, dass ich die vorliegende Arbeit selbständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel benutzt habe und dass die Arbeit in gleicher oder ähnlicher Form noch keiner anderen Prüfungsbehörde vorgelegen hat und von dieser als Teil einer Prüfungsleistung angenommen wurde. Alle Ausführungen, die wörtlich oder sinngemäß übernommen wurden, sind als solche gekennzeichnet.

Die Richtlinien der Arbeitsgruppe für Studien- und Diplomarbeiten habe ich gelesen und anerkannt, insbesondere die Regelung des Nutzungsrechts

Mit der Einstellung dieser Arbeit in die Bibliothek bin ich einverstanden. ja  nein

Der Veröffentlichung dieser Arbeit im Internet stimme ich zu. ja  nein

Koblenz, den .....

Unterschrift



# Inhaltsverzeichnis

- 1 Einleitung** **7**
  - 1.1 Problemstellung . . . . . 7
  - 1.2 Überblick eigene Implementierung . . . . . 9
  - 1.3 Gliederung . . . . . 10
  
- 2 Stand der Wissenschaft** **11**
  
- 3 Erläuterung und Umsetzung der Verfahren** **13**
  - 3.1 Gesamtüberblick . . . . . 13
    - 3.1.1 Voraussetzungen . . . . . 13
    - 3.1.2 Schrittweises Vorgehen . . . . . 15
  - 3.2 Modell des Abbildungsprozesses . . . . . 18
  - 3.3 Synthetische Testbilder . . . . . 23
  - 3.4 Durchschnittsbild . . . . . 23
  - 3.5 Iterative-Back-Projection . . . . . 24
    - 3.5.1 Vorgehen . . . . . 24
  - 3.6 Statistische Verfahren . . . . . 27
    - 3.6.1 Zusammensetzung von M . . . . . 27

3.6.2	Randbehandlung . . . . .	28
3.6.3	Maximum-Likelihood . . . . .	29
3.6.4	Maximum-A-Posteriori . . . . .	31
3.6.5	Priore . . . . .	32
3.6.6	Implementierung . . . . .	36
<b>4</b>	<b>Experimente und Ergebnisse</b>	<b>39</b>
4.1	Fehler zur Ground Truth . . . . .	39
4.2	Laufzeitverhalten . . . . .	40
4.3	Rauschen . . . . .	42
4.4	Registrierungsfehler . . . . .	43
4.5	Reale Bildserie . . . . .	44
<b>5</b>	<b>Zusammenfassung</b>	<b>55</b>

# Kapitel 1

## Einleitung

### 1.1 Problemstellung

In vielen Bereichen der Wissenschaft, Wirtschaft und des alltäglichen Lebens werden hochaufgelöste Bilder benötigt oder sind zumindest wünschenswert. Auf hochaufgelösten medizinischen Bildern lassen sich Krankheiten besser diagnostizieren, auf hochaufgelösten Satellitenbildern lassen sich Massenvernichtungswaffen von harmlosen Lehmhütten unterscheiden und das Standbild des letzten Urlaubsvideos sieht höher aufgelöst (mit Hilfe von zusätzlichen Informationen der umgebenden Frames) auch besser aus.

Die einfachste Möglichkeit die Auflösung zu erhöhen, wäre sicherlich die Anzahl der lichtempfindlichen Elemente auf dem CCD-Chip der Kamera zu erhöhen. Bei begrenzter Sensorgröße führt das zwangsläufig zu weniger Licht pro lichtempfindlichem Element. Das Signalrauschen verstärkt sich, da die lichtempfindlichen Elemente noch dichter gepackt auf dem Chip angeordnet sind und es so häufiger zum Dunkelstromeffekt kommt. Auch technisch sind der Verkleinerung der Sensorelemente Grenzen gesetzt, an die aktuelle Chips schon fast stoßen.

Ein Ausweg aus dieser Situation kann die Auflösungserhöhung (Superresolution, SR) darstellen. Sie versucht ein hochaufgelöstes (High Resolution, HR) Bild oder eine hochaufgelöste Bildserie aus mehreren niedrigaufgelösten (Low Resolution, LR) Bildern der glei-

chen Szene zu erstellen. Dadurch ist es eventuell möglich, niedrig aufgelöste Geräte, mit denen mehrere leicht versetzte Aufnahmen der gleichen Szene gemacht werden können, weiterhin zu verwenden und somit Kosten zu sparen.

Durch zusätzliche Informationen aus mehreren Bildern (Frame Fusion) wird es möglich, Rauschen und Unschärfe zu vermindern, den Bildausschnitt zu vergrößern (Panoramabilder), die Auflösung zu erhöhen (Superresolution) und den Dynamikumfang zu erweitern (Dynamic Range). Aufgabengebiete wären demnach die forensische Bildverarbeitung, Spezialeffekte in der Computergraphik und in der digitalen Videobearbeitung.

Die Kombination mehrerer Bilder zu einem Bild wird erst durch die Registrierung der Eingangsbilder möglich. Im Falle der Superresolution muss diese subpixel genau sein, da es hier darum geht aus den Informationen der Pixelzwischenräume zusätzliche Pixel zu erzeugen und somit die Auflösung zu erhöhen.

## **Anwendungsgebiete**

Die SR hat sich in vielen Bereichen bewährt, in denen es möglich ist, mehrere Bilder der gleichen Szene zu machen. Im Falle von Überwachungskameras ist es oft wünschenswert, bestimmte Bereiche (Region of Interest - ROI) heranzuzoomen, wie beispielsweise das Gesicht eines Verdächtigen oder das Nummernschild eines verdächtigen Fahrzeugs. Bei bildgebenden Verfahren in der Medizin, wie der Computer Aided Tomographie (CT) oder der Magnetresonanztomographie (MRT) ist es möglich, mehrere Aufnahmen zu machen, wohingegen die Auflösung begrenzt ist. Eine aktuelle Anwendung der SR ist durch den Umstieg von PAL (Phase Alternating Line) oder anderen analogen Fernsehnormen auf HDTV (High Definition Television) entstanden, wo es von enormer Bedeutung ist, die SDTV (Standard Definition Television) Signale auf HDTV Geräten ohne störende Artefakte darstellen zu können.

## **Motivation**

Bei einer digitalen Kamera handelt es sich um ein Messinstrument, welches die Helligkeitsintensitäten einer Szene misst. Wie alle digitalen Messinstrumente besitzt sie eine

Transferfunktion, die ein kontinuierliches in ein diskretisiertes Signal umwandelt. Dabei kommt es unweigerlich zu Informationsverlusten durch die Quantisierung. Außerdem kommt es bei digitalen bildgebenden Verfahren häufig zu Rauschen. Bei der Superresolution als Bildrestorationsverfahren kann im Gegensatz zu Einzelbildverfahren der Verlust an Bildinformationen durch Zurückgreifen auf mehrere Bilder ausgeglichen werden. Bei Einzelbildverfahren handelt es sich um ein unterbestimmtes Problem und muss deshalb mit Annahmen über den Intensitätsverlauf arbeiten. Durch die Verwendung mehrerer Bilder können weitere Bedingungen aufgestellt, und das schlecht gestellte Optimierungsproblem verbessert werden.

Durch eine ausreichend akkurate Bildregistrierung ist es möglich, Frequenzen oberhalb der Nyquistgrenze eines einzelnen Bildes wieder herzustellen.

## 1.2 Überblick eigene Implementierung

In dieser Studienarbeit werden die Verfahren Iterative-Back-Projection (IBP), Maximum-Likelihood (ML) und Maximum-A-Posteriori (MAP) implementiert.

Zuerst wird ein Modell des Abbildungsprozesses aufgestellt, welches den Bezug zwischen der kontinuierlichen Szene und den entstandenen Bildern herstellt. Um das inverse Problem der Superresolution lösen zu können, muss der Prozess, in dem die Bildserie entstanden ist, umgekehrt werden.

IBP, das der Rückprojektion in der Computertomographie ähnelt, wird dieser Abbildungsprozess simuliert, indem die Deformationen dieses Vorgangs auf eine Ausgangsschätzung, beispielsweise ein schwarzes Bild, angewandt wird. Die daraus entstehende, simulierte Bildserie wird mit der tatsächlich aufgenommenen Bildserie verglichen und deren Fehler anschließend auf die aktuelle SR Schätzung rückprojiziert. Dieser Vorgang wird solange wiederholt, bis der Fehler zwischen simulierter und tatsächlicher Bildserie unter einen Schwellwert fällt.

Bei den statistischen Verfahren (Maximum-Likelihood und Maximum-A-Posteriori) werden die Bilder als Zufallsgrößen interpretiert, die in einem statistischen Prozess entstanden sind. Mit diesen Zufallsgrößen wird ein Gleichungssystem aufgestellt, das anschließend

iterativ gelöst wird. Die resultierenden Matrizen sind sehr groß und schwach besetzt, sodass auf speziell für solche Matrizen geeignete Methoden zurückgegriffen werden muss. Bei 50 Eingangsbildern der Größe  $40 \times 40$  und einer Skalierung von 3 wird, um das Gleichungssystem aufstellen zu können, eine Systemmatrix  $M$  der Dimension  $80000 \times 14400$  benötigt.

MAP bietet zusätzlich die Möglichkeit verschiedene Priors mit unterschiedlichen Eigenschaften zu verwenden. Es werden der Quadratische Prior, ein mit dem Gradientenbild gewichteter Prior und der Gaussian Markov Random Field Prior eingesetzt.

### 1.3 Gliederung

In Kapitel 2 wird ein Überblick der wichtigsten SR Verfahren gegeben. Kapitel 3 erläutert das grundsätzliche Vorgehen der Superresolution und erklärt die zu implementierenden Verfahren im Speziellen. In Kapitel 4 wurden die Verfahren nach verschiedenen Kriterien miteinander verglichen. Mit Hilfe einer synthetisch erstellten Bildserie, deren Registrierung bekannt ist, wird das Laufzeitverhalten, die Empfindlichkeit gegenüber Rauschen und fehlerhafter Registrierung anhand des Fehlers zur Ground Truth untersucht. Abschließend werden die Ergebnisse in Kapitel 5 zusammengefasst.

# Kapitel 2

## Stand der Wissenschaft

Das Problem der Superresolution wird seit Anfang der 80er Jahre des letzten Jahrhunderts in zahlreichen wissenschaftlichen Artikeln beschrieben. Die frühesten Versuche basierten auf dem Generalized Sampling Theorem [UG92]. Diese konnten jedoch nicht mit Rauschen und Unschärfe in den Ausgangsbildern umgehen.

Die wichtigsten Ansätze können in zwei Bereiche unterteilt werden: Methoden im *Frequenzbereich* (Frequency Domain) und im *räumlichen Bereich* (Spatial Domain). Die Frequenzmethoden können gut mit Rauschen und Unschärfe umgehen, sind allerdings auf reine Translationen zwischen den Eingangsbildern beschränkt und somit nicht auf alle Einsatzgebiete anwendbar [TH84] [TK96]. Des Weiteren ist es nur bedingt möglich, Vorwissen zur Regularisierung des Optimierungsproblems der SR einfließen zu lassen.

Bei den Methoden im räumlichen Bereich hingegen können fast alle Bewegungsmodelle eingesetzt werden. Zusätzlich können sie durch die Möglichkeit, Vorwissen einfließen zu lassen, sehr gut mit Rauschen umgehen. Irani und Peleg haben in [IP91] und [IP93] das Iterative-Back-Projection-Verfahren (IBP) vorgestellt, in dem die SR Schätzung durch eine Fehlerrückprojektion iterativ verbessert wird. Bei IBP ist es jedoch nur bedingt möglich Vorwissen einfließen zu lassen, zudem konvergiert es eher langsam.

Projection onto Convex Sets (POCS) ist ein mengentheoretischer Ansatz, der iterativ das inverse Problem der Superresolution löst [PST97] [EST97]. Bei POCS ist es sehr einfach a priori Wissen einfließen zu lassen und damit die Lösung in eine bestimmte Richtung zu

lenken, beispielsweise ein kantenerhaltendes Ergebnis zu bevorzugen. Der größte Nachteil von POCS ist aber, dass es sehr langsam konvergiert und keine eindeutige Lösung hat.

Eine andere Herangehensweise sind die statistischen Verfahren, zu denen Maximum-Likelihood (ML) und Maximum-A-Posteriori (MAP) gehören [SS96] [EF97] [CZ03]. Hier werden die Bilder als Zufallsgrößen interpretiert, die in einem statistischen Prozess entstanden sind. ML konvergiert sehr schnell, da es gänzlich auf Vorwissen verzichten muss, besteht keine Möglichkeit die Lösung zu beeinflussen. Bei MAP werden bayesianische Verfahren dazu eingesetzt, das Problem zu regularisieren und dadurch die Lösung zu beeinflussen. Es konvergiert sehr schnell und liefert eine eindeutige Lösung, ist robust gegen Rauschen und durch die Möglichkeit verschiedene Priore einzusetzen sehr flexibel. Eine sehr ausführliche Beschreibung der statistischen Verfahren ist in [Cap04] zu finden.

# Kapitel 3

## Erläuterung und Umsetzung der Verfahren

### 3.1 Gesamtüberblick

#### 3.1.1 Voraussetzungen

Die Voraussetzungen für eine Auflösungserhöhung sind zum einen die Verfügbarkeit mehrerer Bilder, die die gleiche Szene beinhalten und zum anderen, dass diese subpixel versetzt zueinander sind, d.h. die Pixel des einen LR Bildes in der HR Bildebene müssen den Pixelzwischenraum des anderen Bildes mit Informationen füllen (vgl. Abb. 3.1). Wenn der Versatz einem Vielfachen eines Pixelabstandes entspricht, kommen keine zusätzlichen Informationen hinzu, da derselbe Punkt durch den Sensor lediglich nochmals abgetastet wird. Eine Auflösungserhöhung im SR Sinne wäre damit nicht möglich.

Die Abtastung eines eindimensionalen Signals ergibt eine Diskretisierung der zugrunde liegenden Funktion. Werden zwei solcher Diskretisierungen, die leicht versetzt sind (subpixel versetzt im Fall der SR), miteinander kombiniert, so ist es möglich, die beiden Messwertreihen zu einer besser abgetasteten Funktion zu vereinen (vgl. Abb. 3.2). In dem Idealfall, dass sie genau um eine halbe Abtastrate versetzt sind, ist eine Verdoppelung der Abtastgenauigkeit möglich.

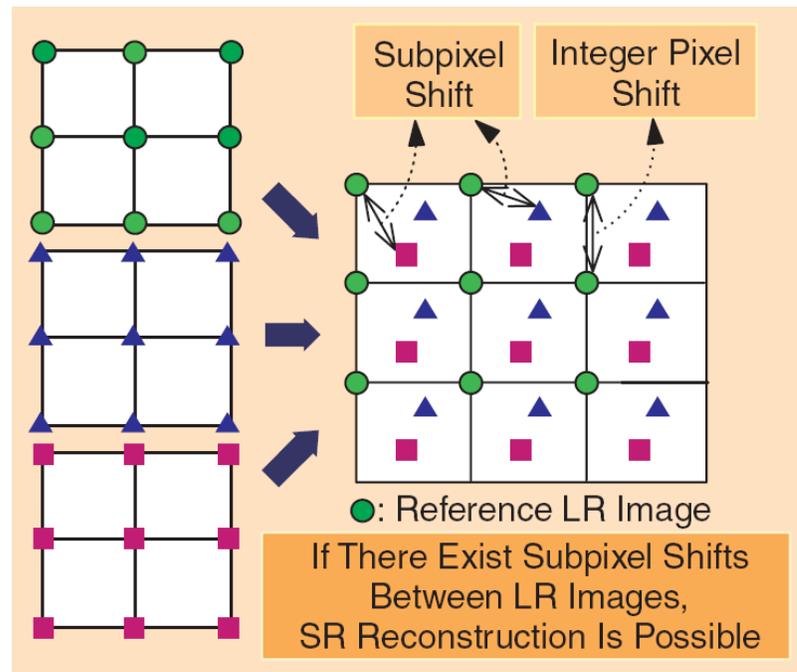


Bild 3.1: Nach der Bildregistrierung müssen die Pixelzwischenräume mit Informationen gefüllt sein, um die SR zu ermöglichen

Ohne diese Bedingung wäre der SR-Ansatz nur unwesentlich besser als die Auflösungserhöhung durch Interpolation, die z. B. beim „Digitalen Zoom“ von Digitalkameras zum Einsatz kommt. Bei einer solchen Auflösungserhöhung existieren keine zusätzlichen Informationen und es ist daher nicht möglich, die verloren gegangenen hochfrequenten Komponenten der Szene wiederherzustellen.

Die zusätzlichen Informationen kommen durch die relative Bewegung von Bild zu Bild zustande. Es werden zwei Arten der Bewegung unterschieden:

- Kontrollierte Bewegung
  - Vorteil: da die Bewegungen bekannt sind, ist die Bildregistrierung leichter
  - Trick: es besteht die Möglichkeit eine solche Bewegung zu forcieren, indem

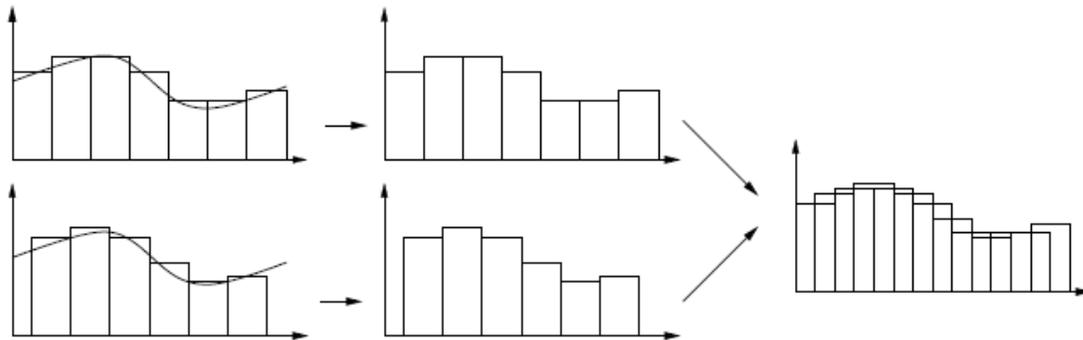


Bild 3.2: Zwei leicht versetzte Diskretisierungen ergeben kombiniert eine genauere Abtastung

der CCD-Chip geringfügig bewegt wird (beispielsweise durch ein Piezoelement), so werden pro Aufnahme mehrere leicht versetzte Bilder aufgenommen und anschließend zu einem höheraufgelösten Bild kombiniert

- Beispiel: die orbitale Bewegung des Kamerasystems eines Satelliten
- Unkontrollierte Bewegung
  - Vorteil: auch bereits gemachte Aufnahmen erfüllen meist diese Kriterien und können somit durch SR Verfahren verbessert werden.
  - Beispiel: ein sich bewegendes Objekt, Vibrationen der Kamera oder Bilder, die ohne Stativ aufgenommen wurden.

### 3.1.2 Schrittweises Vorgehen

Die grundsätzliche Vorgehensweise bei der SR ist in 3 Schritte gegliedert:

- Bildregistrierung
- Interpolation auf die HR Ebene

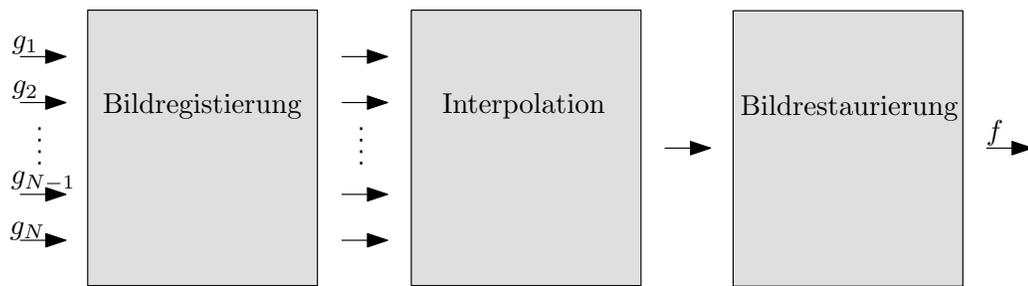


Bild 3.3: Schema der Superresolution

- Bildrestaurierung

Da die vorgestellten Verfahren keine spezielle Bildregistrierung erfordern, kann jedes Registrierungsverfahren eingesetzt werden, das subpixelgenaue Ergebnisse liefert und in der jeweiligen Situation am geeignetsten ist.

Das einfachste SR Verfahren entsteht, wenn die drei Schritte direkt nacheinander angewendet werden. Nach der Registrierung der LR Bildserie ( $g_1$  bis  $g_N$ ), erfolgt die eigentliche Auflösungserhöhung, indem die Bildpunkte der Eingangsbilder auf eine HR Bildebene projiziert und dann gemittelt bzw. auf das HR Gitter interpoliert werden. Anschließend wird das HR Bild mit Hilfe von Bildrestaurierungsverfahren weitestgehend von Unschärfe und Rauschen befreit (vgl. Abb. 3.3).

Ein großer Vorteil dieser Methode ist ihre Effizienz, was sie für bestimmte zeitkritische Anwendungen interessant macht. Die Qualität der Ergebnisse ist im Vergleich mit anderen Methoden allerdings schlechter, da kein Vorwissen mit einfließt und es keine Möglichkeit gibt, den durch den Abbildungsprozess entstandenen Informationsverlust rückgängig zu machen.

### **Bildregistrierung**

Nur wenn die Szenenbewegungen bekannt sind oder abgeschätzt werden können, ist es möglich die LR Bilder zu einem SR Bild zu kombinieren. Die Bildregistrierung, also das

Ausrichten der LR Bilder zueinander, ist ein fester Bestandteil der SR und stellt immer den ersten Schritt im Prozess der Auflösungserhöhung dar.

Mögliche Verfahren sind in zwei Kategorien einzuteilen [CZ98]: direkte und merkmalsbasierte Methoden. Während die direkten Methoden auf den gesamten Bildinformationen arbeiten, benutzen die merkmalsbasierten Methoden lediglich wenige, das Bild charakterisierende Regionen, um die Bilder aneinander auszurichten. Beide Ansätze finden in der SR Verwendung. In Kapitel 4 wird eine direkte und eine merkmalsbasierte Registrierungs- methode auf eine reale Bildserie angewandt und die Ergebnisse miteinander verglichen (vgl. Abb. 4.12).

## **Interpolation**

Nach der Registrierung der LR Bilder sind die Bildpunkte unregelmäßig in der HR Bildebene verteilt und müssen auf das HR Grid interpoliert werden (vgl. Abb. 3.1). Es können direkte oder iterative Methoden zur Interpolation eingesetzt werden, meist wird jedoch auf die effiziente kubische Interpolation zurückgegriffen.

## **Bildrestaurierung**

Im Abbildungsprozess eines digitalen Bildes kommt es unvermeidlich zu Informationsverlust, vor allem im hochfrequenten Bereich. Gründe hierfür können sein:

- optische Störungen - durch die Linsen und Spiegel in der Kamera
- Bewegungsunschärfe - durch zu lange Belichtungszeit ohne Stativ oder sich schnell bewegende Objekte
- Rauschen - durch Quanteneffekte, Dunkelstrom oder bei der Übertragung in den Speicher
- ungenügende Sensordichte

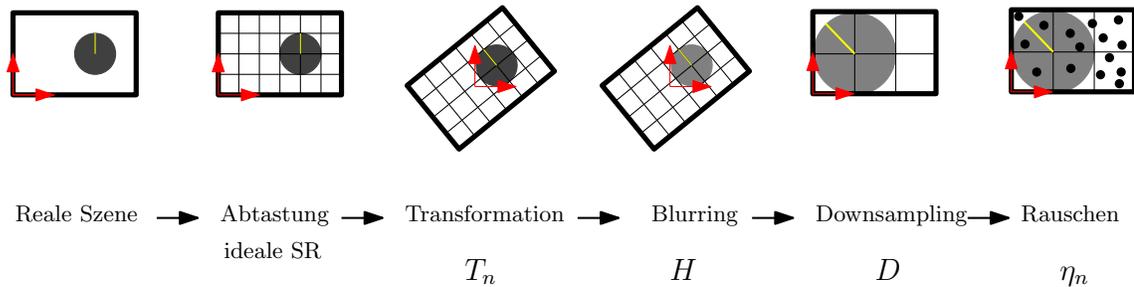


Bild 3.4: Schematische Darstellung des Abbildungsprozesses

Ziel der SR ist es aus diesen verrauschten, unscharfen und zu gering aufgelösten Bildern ein HR Bild der Szene wiederherzustellen. Ein Bestandteil der SR Auflösungs-erhöhung ist daher auch die Bildrestaurierung. Die SR kann gar als eine Erweiterung der Bildrestaurierung angesehen werden, in der die Bilder nicht nur verbessert, sondern auch in ihrer Auflösung erhöht werden. Dies ist möglich, da durch mehrere Eingangsbilder auch mehr Informationen für die Rekonstruktion zur Verfügung stehen.

## 3.2 Modell des Abbildungsprozesses

Um das Problem der SR analysieren zu können, wird ein mathematisches Modell des Abbildungsprozesses benötigt, mit dem die HR Szene mit den LR Bildern in Bezug gesetzt werden kann. Das Modell macht einige Einschränkungen: es wird nur ein HR Bild (keine HR Bildserie) wiederhergestellt und es werden nur Grauwertbilder verwendet. Diese Einschränkungen dienen lediglich dem Ziel der Verständlichkeit; das Modell kann leicht auf allgemeine Fälle erweitert werden.

Die den Abbildungsprozess beeinflussenden Faktoren sind:

- Geometrische Transformation
- Unschärfe
- Downsampling

- Additives Rauschen

Das hier verwendete Modell des Abbildungsprozesses geht davon aus, dass die LR Eingangsbilder aus einem HR Bild entstanden sind:

$$g_n(x, y) = d(h(u, v) \star f(\tau_n(x, y))) + \eta(x, y) \quad (3.1)$$

$f$  - HR Bild

$g_n$  -  $n$ -te LR Bild

$\tau_n$  - Transformation des  $n$ -ten LR Bildes

$h$  - Point Spread Function

$d$  - Downsampling Operator

$\eta_n$  - Rauschen

Die Point Spread Function (PSF)  $h$  wird als linear und positionsunabhängig angesehen. Beim Rauschen  $\eta_n$  handelt es sich um mittelwertfreies Gaußrauschen.

Nach der Diskretisierung kann das Modell in Matrixschreibweise dargestellt werden. Die  $N$  LR Eingangsbilder mit der Größe  $s_1 \times s_2$  werden in lexikographischer Schreibweise als Spaltenvektoren  $\mathbf{g}_n = [g_{n,1}, g_{n,2}, \dots, g_{n,s_1 s_2}]^T$  mit  $n = 1, 2, \dots, N$  dargestellt. Das HR Bild der Größe  $cs_1 \times cs_2$  (wobei  $c$  der Skalierungsfaktor ist) wird in lexikographischer Schreibweise zu  $\mathbf{f} = [f_1, f_2, \dots, f_{cs_1 cs_2}]^T$ .

Gleichung 3.1 kann wie folgt in Matrixschreibweise aufgestellt werden:

$$\mathbf{g}_n = \mathbf{DHT}_n \mathbf{f} + \eta_n, \quad \forall 1 \leq n \leq N \quad (3.2)$$

mit  $\mathbf{f}$  das HR Bild

$\mathbf{g}_n$  das  $n$ -te LR Bild der Serie

$\mathbf{D}$  die Downsamplingmatrix der Größe  $s_1 s_2 \times c s_1 c s_2$

$\mathbf{H}$  die Unschärfematrix der Größe  $c s_1 c s_2 \times c s_1 c s_2$

$\mathbf{T}_n$  die Transformationsmatrix des  $n$ -ten LR Bildes der Größe  $c s_1 c s_2 \times c s_1 c s_2$

$\eta_n$  das additive Rauschen des  $n$ -ten LR Bildes als Vektor der Größe  $s_1 s_2$

Da davon ausgegangen werden kann, dass die drei Matrizen  $\mathbf{D}$ ,  $\mathbf{H}$  und  $\mathbf{T}_n$  bekannt sind, kann demzufolge Gleichung 3.2 auch in folgender Kurzform mit der Systemmatrix  $\mathbf{M}_n = \mathbf{DHT}_n$  ( $\mathbf{M}_n$  ist eine Matrix der Größe  $s_1 s_2 \times c s_1 c s_2$ ) geschrieben werden (siehe Kapitel 3.6.1):

$$\mathbf{g}_n = \mathbf{M}_n \mathbf{f} + \eta_n \quad (3.3)$$

Der letzte Schritt zur Bildung des überbestimmten Lösungssystems stellt die vertikale Konkatenation sämtlicher Bildvektoren und Matrizen dar:

$$\begin{pmatrix} \mathbf{g}_1 \\ \mathbf{g}_2 \\ \vdots \\ \mathbf{g}_n \end{pmatrix} = \begin{pmatrix} \mathbf{M}_1 \\ \mathbf{M}_2 \\ \vdots \\ \mathbf{M}_n \end{pmatrix} \mathbf{f} + \begin{pmatrix} \eta_1 \\ \eta_2 \\ \vdots \\ \eta_n \end{pmatrix} \quad (3.4)$$

$$\mathbf{g} = \mathbf{M} \mathbf{f} + \eta \quad (3.5)$$

## Geometrische Verzerrung

Zuerst muss das Koordinatensystem des hochaufgelösten Bildes festgelegt werden. Hierzu wird meist das Koordinatensystem des ersten Bildes der Sequenz als Ursprung genutzt und entsprechend vergrößert.

Das HR Bild wird durch Spiegelungen, Skalierungen und Translationen auf den CCD-Chip transformiert. In einer Kamera wird dies durch Spiegel und Linsen erreicht, die aber bedingt durch den Fertigungsprozess und die Materialeigenschaften fehlerhaft sind. Der dadurch entstehende Fehler, in Form von tonnen- bzw. kissenförmigen Verzerrungen und radialen Verzeichnungen, kann durch geeignete Verfahren reduziert werden.

Die Deformationen eines LR Bildes  $g_n$  werden im Modell durch die Transformationsmatrix  $T_n$  repräsentiert, die aus den Daten der Bildregistrierung errechnet wird. Es ist für den gesamten Prozess der SR von entscheidender Bedeutung, dass diese Informationen möglichst präzise sind.

IBP fordert zusätzlich noch, dass die Verzerrungsmatrix  $T_n$  invertierbar ist, da mit ihrer Hilfe der Abbildungsprozess für die Rückprojektion eines Fehlerbildes umgekehrt wird.

## Unschärfe

Viele Arten der Unschärfe haben einen Einfluss auf den Abbildungsprozess:

- optische Unschärfe - Objekt nicht im Fokus
- Bewegungsunschärfe - durch relative Bewegung zwischen der Kamera und der realen Szene
- Linsenunschärfe - durch nicht ideale Linsen

Bei der Linsenunschärfe wird ein Punktlichtstrahl durch die Linse nicht auf einen Punkt, sondern eine Kreisfläche variierender Intensitäten projiziert. Diese Kreisfläche mit dem Radius  $\sigma$  (auch Unschärfe der Kamera genannt) wird durch die Point Spread Function

(PSF) beschrieben. Eine gute Annäherung der PSF bei weißem Licht stellt eine zweidimensionale Gaußfunktion dar, deren Standardabweichung  $\sigma_{Gau\beta}$  proportional zum Radius  $\sigma$  ist.

Die korrekte PSF ist schwer zu bestimmen und kann nur in den seltensten Fällen vom Kamerahersteller bezogen werden. Man ist deshalb darauf angewiesen, sie auf andere Weise zu bestimmen bzw. zu schätzen. Z. B. ist es möglich, sie durch ein Testbild (Irani und Peleg: Kreis auf ein weißes Papier zeichnen und ein Bild davon machen) oder auf der Grundlage der Bildserie „blind“ zu schätzen.

### **Abtastung**

Die Downsamplingmatrix  $D$  erstellt aus dem transformierten und unscharfen HR Bild ein LR Bild. Die hier erfolgende Verringerung der Auflösung wirkt wie ein Mittelwertfilter, da mehrere Bildpunkte zu einem zusammengefasst werden.

Bei heute üblichen CCD-Chips, ist der lichtempfindliche Teil kleiner als die zu einem Bildpunkt gehörende Matrixfläche. Deshalb werden Details zwischen den lichtempfindlichen Teilen nicht erfasst, was zusätzlich einer Tiefpassfilterung entspricht.

Theoretisch ist der Verkleinerungs- bzw. Vergrößerungsfaktor beliebig, allerdings erhöht sich bei steigender Vergrößerung die Zahl der Unbekannten, wobei die Anzahl der Gleichungen konstant bleibt. Dies führt zu einem schlecht formulierten Optimierungsproblem. Eine Faustregel besagt, dass die Menge der Daten, die durch die Bilder der Sequenz gegeben ist, größer sein sollte, als die der wiederherzustellenden Szene.

### **Additives Rauschen**

Das Auslesen der Intensitätswerte aus dem CCD-Chip kann nicht ganz fehlerfrei geschehen, denn kurze Störungen im Signal verändern die Daten und führen zu Rauschen. Auch Quanteneffekte führen dazu, dass Photonen, die sich eigentlich geradlinig ausbreiten, nicht oder nicht an der richtigen Stelle des Sensors auftreffen.

Das Rauschen stellt keinen systematischen, sondern einen statistischen Fehler dar, weil er

zwischen zwei Grauwerten unkorreliert ist. Wie bei den meisten Bildrestaurierungsverfahren wird auch bei der SR davon ausgegangen, dass es sich beim Rauschen um additives, mittelwertfreies Gaußrauschen handelt. Diese Annahme entspricht in den meisten Fällen nicht der Realität, liefert aber dennoch gute Ergebnisse. Ein realistischeres Modell würde zu einem sehr komplexen Optimierungsproblem führen, das dementsprechend schwer zu lösen wäre.

### 3.3 Synthetische Testbilder

Die in dieser Studienarbeit verwendeten synthetischen Bildserien wurden erstellt, indem der Abbildungsprozess auf das Ground Truth Bild angewandt wurde, ähnlich der Simulation des Abbildungsprozesses bei IBP. Zu ihrer Erstellung wurde auf eine zufällig entstandene Homographie zurückgegriffen. Dadurch ist die volle Kontrolle über den Abbildungsprozess gegeben, d.h. Faktoren, die die SR Abschätzung beeinflussen, wie die Genauigkeit der Registrierung, die Genauigkeit der PSF und das Rauschen der Eingangsbilder können variiert werden und so deren Einfluss auf die SR Abschätzung untersucht werden. Synthetische Testbilder bieten des Weiteren den Vorteil, die Ergebnisse mit dem zugrunde liegenden Ground Truth Bild vergleichen zu können. Dadurch wird es möglich, die verschiedenen Verfahren mittels eines objektiven Fehlermaßes miteinander zu vergleichen.

### 3.4 Durchschnittsbild

Das Durchschnittsbild stellt eine stark weichgezeichnete Version der Superresolution dar. Deshalb liefert es eine gute, erste Annäherung an die Superresolution und kann als Startpunkt für deren Abschätzung genutzt werden. Des Weiteren ist es äußerst unanfällig gegenüber Rauschen. Es kann in der Randbehandlung als nachvollziehbare Abschätzung der Bereiche außerhalb der Region of Interest dienen (siehe Kapitel 3.6.2).

Gebildet wird das Durchschnittsbild, indem das gewichtete Mittel aller LR Pixel, die einen bestimmten SR Pixel beeinflussen, berechnet wird. In dem zugrunde liegenden Abbildungsmodell beschreibt eine Spalte der Matrix  $M$  alle von einem bestimmten SR Pixel

(z. B.  $f_1$ ) beeinflussten LR Pixel. Nicht-Null-Einträge in dieser Spalte stellen die beeinflussten LR Pixel dar.

Um das gewichtete Mittel eines speziellen SR Pixels aus den LR Pixeln, die ihn beeinflussen, zu berechnen, kann eine solche Spalte normalisiert und damit das Skalarprodukt mit dem Vektor der Eingangsbilder  $\mathbf{g}$  gebildet werden.

Es kann eine Matrix  $\mathbf{K}^{-1}$  gebildet werden, die, mit der transponierten Systemmatrix  $\mathbf{M}^T$  multipliziert,  $\mathbf{M}$  zeilenweise normalisiert und damit diese Aufgabe erfüllt. Diese zeilenweise normalisierte Matrix  $\mathbf{K}^{-1}\mathbf{M}^T$  ergibt multipliziert mit  $\mathbf{g}$  das Durchschnittsbild.

$$\mathbf{f}_{avg} = \mathbf{K}^{-1}\mathbf{M}^T\mathbf{g} \quad (3.6)$$

Die Normalisierungsmatrix  $\mathbf{K}$  wird wie folgt gebildet:

$$K_{ii} = \sum_{\forall j} M_{ji} \quad (3.7)$$

## 3.5 Iterative-Back-Projection

### 3.5.1 Vorgehen

In diesem Verfahren von Irani und Peleg [IP91] [IP93], das der Rückprojektion in der Tomographie sehr ähnlich ist, wird zuerst der Abbildungsprozess simuliert, die dadurch entstandene simulierte LR Bildserie mit der tatsächlichen verglichen, und der resultierende Fehler dann auf das simulierte HR Bild rückprojiziert. Eine erste Schätzung des SR Bildes wird schrittweise verbessert, bis der Fehler  $e^{(i)}$  zwischen der simulierten und der aufgenommenen Bildserie ( $\hat{\mathbf{g}} - \mathbf{g}$ ) unter einen Schwellwert  $\epsilon$  fällt. Als erste Schätzung liefert das hochskalierte Durchschnittsbild der Eingangsbilder gute Ergebnisse.

#### 1. Simulation des Abbildungsprozesses

- Bildserie  $\hat{\mathbf{g}}_n^{(i)}$  aus  $\hat{\mathbf{f}}^{(i)}$  bilden

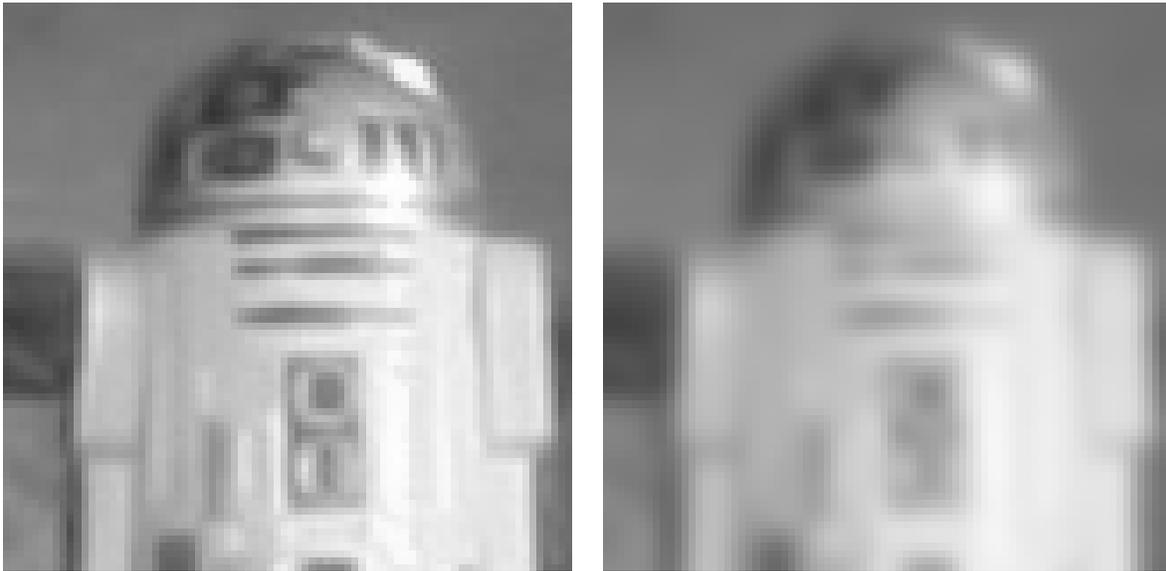


Bild 3.5: links: Ground Truth, rechts: Durchschnittsbild ( $\sigma = 1.4$ )

2. Vergleichen der echten mit der simulierten Bildserie

- Fehler errechnen  $\{\hat{g}_n^{(i)} - g_n\}_{n=1}^N$

3. Rückprojektion des Fehlers

- $\hat{f}^{(i+1)}$  aus  $\hat{f}^{(i)}$  und dem Fehler bilden

4. Wiederhole Schritt 1 - 3 bis Fehlerfunktion unter dem Schwellwert liegt

- $e^{(i)} < \epsilon$

- $\hat{\mathbf{f}}^{(i)}$  die SR Abschätzung im  $i$ -ten Iterationsschritt
- $\mathbf{g}_n$  das  $n$ -te LR Bild der Serie
- $\mathbf{g}_n^{(i)}$  die Abschätzung des  $n$ -ten LR Bildes im  $i$ -ten Iterationsschritt
- $e^{(i)}$  der Fehler im  $i$ -ten Iterationsschritt
- $\epsilon$  der Fehlerschwellwert

Für eine schematische Darstellung der Iterationsschritte siehe Abb. 3.6.

Die Iterative-Back-Projection (IBP) kann nach Elad und Feuer [EF97], unter Verwendung von Gleichung 3.3, in Matrixschreibweise folgendermaßen ausgedrückt werden:

$$\hat{\mathbf{g}}_n^{(i)} = \mathbf{M}_n \hat{\mathbf{f}}^{(i)}$$

$$\hat{\mathbf{f}}^{(i+1)} = \hat{\mathbf{f}}^{(i)} + \sum_{n=1}^N \mathbf{H}^{BP} (\mathbf{g}_n - \hat{\mathbf{g}}_n^{(i)})$$

- wobei  $\hat{\mathbf{f}}^{(i)}$  das simulierte HR Bild im  $i$ -ten Iterationsschritt,
- $\hat{\mathbf{g}}_n^{(i)}$  das  $n$ -te simulierte LR Bild der Serie im  $i$ -ten Iterationsschritt,
- $\mathbf{H}^{BP}$  die Rückprojektionsmatrix (back projection kernel) und
- $\mathbf{g}_n - \hat{\mathbf{g}}_n^{(i)}$  der Fehler im  $i$ -ten Schritt ist.

Die Matrix  $\mathbf{H}^{BP}$  legt fest, wie stark der Fehler  $\mathbf{g}_n - \hat{\mathbf{g}}_n$  den HR Bildpunkt beeinflusst. Im Gegensatz zu der Unschärfematrix, kann  $\mathbf{H}^{BP}$  beliebig festgelegt werden. Dadurch wird es theoretisch möglich  $\mathbf{H}^{BP}$  als eine, die Lösung beeinflussende, Nebenbedingung zu nutzen. In der Praxis gibt es jedoch keine Möglichkeit,  $\mathbf{H}^{BP}$  sinnvoll zu erstellen. Irani und Peleg schlagen  $\mathbf{H}^{PSF}$  (die Unschärfematrix) als eine mögliche Wahl für  $\mathbf{H}^{BP}$  vor.

## 3.6 Statistische Verfahren

### 3.6.1 Zusammensetzung von $M$

Die aus der Transformationsmatrix  $T$ , der Downsamplingmatrix  $D$  und der PSF-Matrix  $H$  zusammengesetzte Matrix  $M$  beschreibt in jeder Zeile den diskretisierten Abbildungsprozess für einen einzelnen LR Pixel (siehe Gleichung 3.1). Die Nicht-Null Werte in einer Zeile von  $M$  stellen die HR Pixel dar, die den LR Pixel beeinflussen. Jeweils mit dem Grad der Beeinflussung als Gewichtung. Es wird sozusagen das Skalarprodukt zwischen dem  $n$ -ten Zeilenvektor der Matrix  $M$  und dem HR Bild  $f$  gebildet, um den  $n$ -ten LR Pixel zu simulieren.

Eine Spalte in der Matrix  $M$  enthält alle LR Pixel, die von einem bestimmten HR Pixel beeinflusst werden. Die Nicht-Null Werte in dieser Spalte stellen die LR Pixel der Bildserie  $g$  dar, auf die der HR Pixel einen Einfluss ausübt. Auch hier jeweils mit dem Grad der Beeinflussung als Gewichtung, allerdings mit dem Unterschied, dass eine Spalte im Gegensatz zu einer Zeile nicht auf Eins normiert ist. Die  $n$ -te Spalte sagt somit aus, wie der  $n$ -te HR Pixel  $f_n$  die gesamte LR Bildserie  $g$  beeinflusst.

Die Eingangsbilder können vorab aneinander ausgerichtet werden, indem die Transformationen mit Hilfe eines geeigneten Interpolationsverfahrens auf sie angewandt werden. Die so entstehenden Zwischenbilder können gespeichert und als neue, nicht zu transformierende Eingangsbilder verwendet werden. Dadurch wird die Transformationsmatrix  $T_n$  überflüssig, die als einzige der drei Matrizen von einem konkreten Eingangsbild abhängt. Dies bietet den Vorteil, eine von den Eingangsbildern unabhängige Matrix  $M$  nutzen zu können, die im Voraus berechnet werden kann. Auf diese Weise lässt sich die Laufzeit drastisch reduzieren, und die so entstandene Matrix  $M$ , aus Downsampling und der diskretisierten PSF, hängt nun nur noch von der Anzahl der Eingangsbilder, von  $\sigma$ , dem Skalierungsfaktor und der Größe der ROI ab. Die Dimension der letztlich vorab gespeicherten Matrix  $M^T M$  hängt hingegen ausschließlich vom Skalierungsfaktor ab. Sie wird in einem speziell für schwach besetzte Matrizen konzipierten und komprimierten Format, dem Harwell-Boeing Format gespeichert. Deren Größe ist von der Anzahl der Nicht-Null Werte, die sich in der Matrix befinden, abhängig. Eine Matrix  $M^T M$  bei dreifacher Ver-

größerung mit einer PSF mit  $\sigma$  1.6, also einem hohen Anteil an Nicht-Null Werten, hat beispielsweise eine Größe von 139 MB.

Um das Downsampling und die PSF in einem Schritt anwenden zu können, wird das Zwischenbild mit der PSF nur an den Positionen gefiltert, an denen sich die LR Pixelmittelpunkte befinden und dadurch das LR Bild erstellt. Somit ist auch die Reihenfolge, zuerst die PSF und anschließend die Auflösungsreduzierung durchzuführen, gewahrt, die für ein erfolgreiches Umkehren des Abbildungsprozesses notwendig ist.

### 3.6.2 Randbehandlung

Da aufgrund der sehr großen und schwach besetzten Matrizen, die bei den statistischen Verfahren zum Einsatz kommen, nur relativ kleine Bereiche (Region of Interest), in der Auflösung erhöht werden können, kommt der Randbehandlung ein sehr hoher Stellenwert zu, da die Randpixel prozentual einen großen Anteil an der ROI haben. Bei großen Bereichen kann eher auf einige Informationen am Rand verzichtet werden, bei einem Bereich von  $40 \times 40$  Pixel hingegen, wie es in der momentanen Implementierung der Fall ist, und einer  $5 \times 5$  PSF würde ein Rand von 2 Pixel entstehen, und somit gingen 19% der verfügbaren Information verloren.

Es existieren einige Arten der Randbehandlung aus der Einzelbildverarbeitung, aber dadurch, dass nur ein bestimmter Bereich (ROI) des Gesamtbildes betrachtet wird und aus den Möglichkeiten die sich durch die Bildserie ergeben, kann der äußere Bereich gut durch das effizient zu berechnende Durchschnittsbild abgeschätzt werden. Das SR Bild  $f$  kann durch das Durchschnittsbild um einen Rand ergänzt werden, sodass die PSF aller SR Pixel darin enthalten sind.

Die durch das Durchschnittsbild erweiterten Bildbereiche bleiben in jedem Abschätzungsschritt konstant. So ist es möglich, den erweiterten Bildvektor  $f$  in  $f_{free}$  und  $f_{fixed}$  zu unterteilen. Gleiches gilt für die Matrix  $M$ . Die Gleichung des Abbildungsprozesses sieht dann folgendermaßen aus:

$$\mathbf{g} = \begin{pmatrix} \mathbf{M}_{inside} & \mathbf{M}_{outside} \end{pmatrix} \begin{pmatrix} \mathbf{f}_{free} \\ \mathbf{f}_{fixed} \end{pmatrix} \quad (3.8)$$

Durch diese Unterteilung wird es möglich, den Einfluss der konstanten Bereiche von  $\mathbf{f}$  aus  $\mathbf{g}$  herauszurechnen:

$$\begin{aligned} \mathbf{g} &= \mathbf{M}_{inside} \mathbf{f}_{free} + \mathbf{M}_{outside} \mathbf{f}_{fixed} + \eta \\ \mathbf{g} - \mathbf{M}_{outside} \mathbf{f}_{fixed} &= \mathbf{M}_{inside} \mathbf{f}_{free} + \eta \end{aligned} \quad (3.9)$$

Diese Manipulation von  $\mathbf{g}$  wird vor dem Schritt der Abschätzung des SR Bildes vorgenommen und erhöht die Laufzeit der Abschätzung somit nicht.

### 3.6.3 Maximum-Likelihood

Bei den statistischen Verfahren werden die LR Bilder und das HR Bild als Zufallsgrößen interpretiert, die in einem statistischen Prozess entstanden sind. Beim **Maximum-Likelihood-Verfahren** wird ein Wahrscheinlichkeitsmodell aufgestellt, nach dem diese Zufallsgrößen entstanden sind. Es handelt sich um die Wahrscheinlichkeit, dass bei gegebener SR Schätzung  $\hat{\mathbf{f}}$ , das LR Bild  $\mathbf{g}_n$  entsteht.

$$P(\mathbf{g}_n | \hat{\mathbf{f}}) = \prod_{\forall x,y} \frac{1}{\sigma_n \sqrt{2\pi}} \exp \left( -\frac{(\hat{g}_n(x,y) - g(x,y))^2}{2\sigma_n^2} \right)$$

Die zugehörige Log-Likelihood ist:

$$\begin{aligned} \mathcal{L}(\mathbf{g}_n) &= - \sum_{\forall x,y} (\hat{g}_n(x,y) - g_n(x,y))^2 \\ &= - \|\hat{\mathbf{g}}_n - \mathbf{g}_n\|^2 \\ &= - \|\mathbf{M}_n \hat{\mathbf{f}} - \mathbf{g}_n\|^2 \end{aligned}$$

Der Übergang zur Log-Likelihood bietet den Vorteil, dass aus den Produkten leichter zu handhabende Summen werden.  $\sigma_n$  beeinflusst die Lösung des Optimierungsproblems nicht und kann vernachlässigt werden.

Auf alle Bilder angewandt ergibt sich:

$$\sum_{\forall n} \mathcal{L}(\mathbf{g}_n) = - \sum_{\forall n} \left\| \mathbf{M}_n \hat{\mathbf{f}} - \mathbf{g}_n \right\|^2 = - \left\| \mathbf{M} \hat{\mathbf{f}} - \mathbf{g} \right\|^2$$

Die Modelldaten werden nun so bestimmt, dass die Likelihood maximiert wird (ML-Prinzip), d.h. es wird das HR Bild gesucht, das mit der höchsten Wahrscheinlichkeit die Bildserie  $\mathbf{g}$  erzeugt hat:

$$\begin{aligned} \mathbf{f}_{ML} &= \underset{\mathbf{f}}{\operatorname{argmin}} \left\| \mathbf{M} \mathbf{f} - \mathbf{g} \right\|^2 \\ &= \underset{\mathbf{f}}{\operatorname{argmin}} (\mathbf{M} \mathbf{f} - \mathbf{g})^T (\mathbf{M} \mathbf{f} - \mathbf{g}) \\ &= \underset{\mathbf{f}}{\operatorname{argmin}} (\mathbf{f}^T \mathbf{M}^T - \mathbf{g}^T) (\mathbf{M} \mathbf{f} - \mathbf{g}) \\ &= \underset{\mathbf{f}}{\operatorname{argmin}} (\mathbf{f}^T \mathbf{M}^T \mathbf{M} \mathbf{f} - \mathbf{f}^T \mathbf{M}^T \mathbf{g} - \mathbf{g}^T \mathbf{M} \mathbf{f} + \mathbf{g}^T \mathbf{g}) \\ &= \underset{\mathbf{f}}{\operatorname{argmin}} (\mathbf{f}^T \mathbf{M}^T \mathbf{M} \mathbf{f} - 2 \mathbf{f}^T \mathbf{M}^T \mathbf{g} - \mathbf{g}^T \mathbf{g}) \end{aligned}$$

Um diese Gleichung zu minimieren, wird die partielle Ableitung nach  $\mathbf{f}$  gebildet und gleich Null gesetzt.

$$\frac{\delta \Phi}{\delta \mathbf{f}} = 2 \mathbf{M}^T \mathbf{M} \mathbf{f} - 2 \mathbf{M}^T \mathbf{g} = 0$$

Nach  $\mathbf{f}$  aufgelöst ergibt sich die Schätzung:

$$\begin{aligned} \mathbf{f} &= (\mathbf{M}^T \mathbf{M})^{-1} \mathbf{M}^T \mathbf{g} \\ &= \mathbf{M}^+ \mathbf{g} \end{aligned}$$

Wobei  $M^+$  die Pseudoinverse (Moore-Penrose) von  $M$  ist. Diese sehr große und schwach besetzte Matrix lässt sich mit iterativen Methoden, wie beispielsweise dem Conjugate-Gradient-Verfahren, lösen.

### 3.6.4 Maximum-A-Posteriori

Das Maximum-A-Posteriori-Verfahren (MAP), einem Vertreter der Bayes-Schätzer, erweitert ML um Vorwissen in Form eines Priors, der in der Lage ist, das schlecht gestellte Optimierungsproblem zu regularisieren. Damit stellt ML eine Variante von MAP ohne Prior dar. Es wird die Wahrscheinlichkeit, dass das simulierte SR Bild  $\hat{\mathbf{f}}$  bei gegebenem Merkmals- bzw. Bildvektor  $\mathbf{g}$  entstanden ist maximiert. Bei dieser Wahrscheinlichkeit  $P(\hat{\mathbf{f}}|\mathbf{g})$  handelt es sich um den Posterior.

$$\mathbf{f}_{MAP} = \operatorname{argmax}_{\hat{\mathbf{f}}} P(\hat{\mathbf{f}}|\mathbf{g})$$

Aus der Anwendung der Bayes-Regel<sup>1</sup> und Logarithmierung resultiert folgendes Optimierungsproblem:

$$\begin{aligned} \mathbf{f}_{MAP} &= \operatorname{argmax}_{\hat{\mathbf{f}}} \frac{P(\hat{\mathbf{f}})P(\mathbf{g}|\hat{\mathbf{f}})}{P(\mathbf{g})} \\ \mathbf{f}_{MAP} &= \operatorname{argmax}_{\hat{\mathbf{f}}} \ln P(\hat{\mathbf{f}}) + \ln P(\mathbf{g}|\hat{\mathbf{f}}) \\ &= \operatorname{argmax}_{\hat{\mathbf{f}}} \ln P(\hat{\mathbf{f}}) - \frac{1}{2\sigma_n^2} \|\mathbf{M}\hat{\mathbf{f}} - \mathbf{g}\|^2 \end{aligned}$$

Da  $P(\mathbf{g})$  konstant ist, spielt es bei der Maximierung keine Rolle und kann weggelassen werden. Die genaue Form von  $P(\hat{\mathbf{f}})$  hängt vom genutzten Vorwissen ab und beeinflusst das Ergebnis in eine bestimmte Richtung. Der große Vorteil des MAP-Verfahrens ist die

---

<sup>1</sup> $P(A|B) = \frac{P(B|A)P(A)}{P(B)}$

Möglichkeit, verschiedene Priore einsetzen zu können, und somit unterschiedliches Vorwissen einfließen zu lassen. Weitere Vorteile dieser Methode sind neben ihrer Flexibilität, die Robustheit und die Eindeutigkeit der Lösung.

### 3.6.5 Priore

Aus der unerschöpflichen Menge der Priore wurden drei zur weiteren Untersuchung ausgewählt. Der Quadratische Prior mit stark glättender Wirkung, verspricht gute Ergebnisse auch bei stark verrauschten Eingangsbildern. Der mit dem Gradientenbild gewichtete Prior soll kantenverstärkende Ergebnisse liefern und der Gaussian Markov Random Field Prior (GMRF), der ebenfalls ein glättender Prior ist, soll durch die Korrelation zwischen Pixeln zu schärferen Ergebnissen führen. Zu erwähnen wäre noch ein besonders für Text geeigneter Prior, der Huber Markov Random Field Prior (HMRF), der aufgrund dieser Spezialisierung nicht implementiert wurde.

#### Quadratischer Prior

Die einfachste und am häufigsten genutzte Form stellt ein quadratischer Prior dar.

$$P(\mathbf{f}) = \frac{1}{Z} \exp -(\mathbf{f}^T \mathbf{Q} \mathbf{f}) \quad (3.10)$$

$Z$  ist hier eine Normalisierungskonstante und  $\mathbf{Q}$  eine symmetrische, positiv definite Matrix.

Wenn  $\mathbf{Q}$  in Gleichung 3.10 ein Mehrfaches der Einheitsmatrix ist, so ist das gleichbedeutend mit der Annahme, dass die Pixel des Bildes mittelwertfrei gaußverteilt sind. Um die Vorteile des Durchschnittsbildes zu nutzen, wird es anstatt des Mittelwerts genutzt. Dies hat zur Folge, dass das Ergebnis der guten SR Abschätzung ähnelt, die das Durchschnittsbild darstellt. Der entsprechende Gibbs Prior lautet:

$$P(\mathbf{f}) = \frac{1}{Z} \exp\left(-\frac{\|\mathbf{f} - \mathbf{f}_{avg}\|^2}{2\sigma_f^2}\right)$$

Dieser Prior ist kein echtes Markov Random Field, da keine räumliche Korrelation zwischen den Pixeln existiert.

$$\mathbf{f}_{MAP} = \operatorname{argmax}_{\mathbf{f}} \frac{1}{2\sigma_f^2} \|\mathbf{f} - \mathbf{f}_{avg}\|^2 - \frac{1}{2\sigma_n^2} \|\mathbf{M}\mathbf{f} - \mathbf{g}\|^2$$

$\sigma_f^2$  ist ein der Varianz ähnlicher Wert, der die Streuung der Verteilung reguliert und normalerweise nicht a priori bekannt ist. Gleiches gilt für das Bildrauschen  $\sigma_n^2$ , welches nur schwer akkurat abgeschätzt werden kann. Deshalb werden die beiden Werte zu einem, die Lösung beeinflussenden, Parameter  $\lambda$  zusammengefasst, der das Verhältnis der beiden darstellt. Die MAP Abschätzung wird so zu:

$$\mathbf{f}_{MAP} = \operatorname{argmax}_{\mathbf{f}} -\lambda \|\mathbf{f} - \mathbf{f}_{avg}\|^2 - \|\mathbf{M}\mathbf{f} - \mathbf{g}\|^2$$

Die daraus resultierende und zu optimierende Gleichung lautet:

$$(\lambda \mathbf{E} - \mathbf{M}^T \mathbf{M}) \mathbf{f} = \lambda \mathbf{f}_{avg} - \mathbf{M}^T \mathbf{g} \quad (3.11)$$

hier ist  $\lambda \mathbf{E}$  ein Mehrfaches der Einheitsmatrix.

Eigenschaften:

- Quadratische Optimierung möglich (Conjugate Gradient Descent)
- sehr Robuster gegenüber Rauschen
- stark geglättete Lösung

### Durch Gradientenbild gewichteter Quadratischer Prior

Ein Nachteil des quadratischen Priors ist, dass durch dessen glättende Eigenschaft viele der Details unterdrückt werden, die es wiederherzustellen gilt. Um eine kantenstärkende Lösung zu erzielen, kann der Prior zusätzlich mit dem Gradientenbild des Durchschnittsbildes gewichtet werden. Bereiche, die im Gradientenbild eine hohe Intensität aufweisen fließen dadurch stärker in die Lösung ein.

$$\mathbf{f}_{MAP} = \operatorname{argmax}_{\mathbf{f}} \frac{1}{2\sigma_f^2} \|\Lambda_{grad}(\mathbf{f} - \mathbf{f}_{avg})\|^2 - \frac{1}{2\sigma_n^2} \|\mathbf{M}\mathbf{f} - \mathbf{g}\|^2$$

hier ist  $\Lambda_{grad} = \operatorname{diag}(|f'_{avg}|)^{-1}$ , die reziproke Diagonalmatrix der Ableitung des Durchschnittsbildes.

Die nicht bekannten Werte wieder zu einem Parameter  $\lambda$  zusammengefasst:

$$\mathbf{f}_{MAP} = \operatorname{argmax}_{\mathbf{f}} \lambda \|\Lambda_{grad}(\mathbf{f} - \mathbf{f}_{avg})\|^2 - \|\mathbf{M}\mathbf{f} - \mathbf{g}\|^2 \quad (3.12)$$

Die daraus resultierende und zu optimierende Gleichung lautet:

$$(\mathbf{M}^T \mathbf{M} + \lambda \Lambda_{grad}) \mathbf{f} = \mathbf{M}^T \mathbf{g} + \lambda \Lambda_{grad} \mathbf{f}_{avg} \quad (3.13)$$

Eigenschaften:

- Quadratische Optimierung möglich (CG)
- kantenverstärkender Prior

### Gaussian Markov Random Field Prior

Wie beim quadratischen Prior wird davon ausgegangen, dass die Pixel des Bildes mittelwertfrei gaußverteilt sind, allerdings mit der zusätzlichen Annahme, dass die Pixel korreliert sind, d.h. es besteht ein Zusammenhang zwischen benachbarten Pixeln.

Wenn die Matrix  $Q$  in Gleichung 3.10 keine Diagonalmatrix ist, so handelt es sich um eine multivariate (mehrdimensionale) Gaußverteilung über  $f$ . Die Werte außerhalb der Diagonale definieren die Korrelation zwischen den Pixeln. Um  $Q$  zu bilden, wird häufig ein Operator  $L$  verwendet, der die erste oder zweite Ableitung von  $f$  bildet, womit  $Q$  dann  $L^T L$  entspricht. In den folgenden Beispielen wird die erste Ableitung genutzt. Dazu wird eine Matrix  $L$  gebildet, die ein kombiniertes Gradientenbild in vertikaler, horizontaler und diagonalen Richtung erstellt.

$$\begin{aligned}d_x &= f_{x+1,y} - f_{x,y} \\d_y &= f_{x,y+1} - f_{x,y} \\d_{xy} &= \frac{1}{\sqrt{2}}(f_{x+1,y+1} - f_{x,y}) \\d_{yx} &= \frac{1}{\sqrt{2}}(f_{x+1,y-1} - f_{x,y})\end{aligned}$$

Die nicht a priori bekannten Werte werden wieder zu einem Parameter  $\lambda$  zusammengefasst, sodass sich folgende Gleichung ergibt:

$$f_{MAP} = \underset{f}{\operatorname{argmax}} \lambda \|L f\|^2 - \|M f - g\|^2$$

Die daraus resultierende und zu optimierende Gleichung lautet:

$$(M^T M - \lambda L^T L) f = M^T g \quad (3.14)$$

Eigenschaften:

- Quadratische Optimierung möglich (CG)
- robust gegenüber Rauschen
- verstärken räumlicher Schärfe

## Huber Markov Random Field Prior

Ein Prior, der besonders für das Wiederherstellen von Text geeignet ist, da er zusammenhängende konstante Flächen begünstigt, ist der Huber Markov Random Field Prior (HMRF).

$$\mathbf{f}_{MAP} = \operatorname{argmax}_{\mathbf{f}} \gamma \rho(\mathbf{L}\mathbf{f}) - \frac{1}{2\sigma_n^2} \|\mathbf{M}\mathbf{f} - \mathbf{g}\|^2$$

Eigenschaften:

- nichtlineare Optimierung notwendig (Globalized Newton Method)
- robust gegenüber Rauschen
- kantenerhaltenden Lösung
- besonders geeignet für Bilder mit stückweise konstanten Intensitäten, wie Text

### 3.6.6 Implementierung

Den statistischen Verfahren ist gemein, dass sie mit sehr großen und schwach besetzten Matrizen arbeiten. Zu diesem Zweck habe ich auf die, auf solche Matrizen spezialisierte, Bibliothek SparseLib++ zurückgegriffen. Da sie einige benötigte Operationen, wie beispielsweise die *Sparse-Matrix* × *Sparse-Matrix*-Multiplikation nicht beinhaltet, musste die Bibliothek um einige Funktionen erweitert werden.

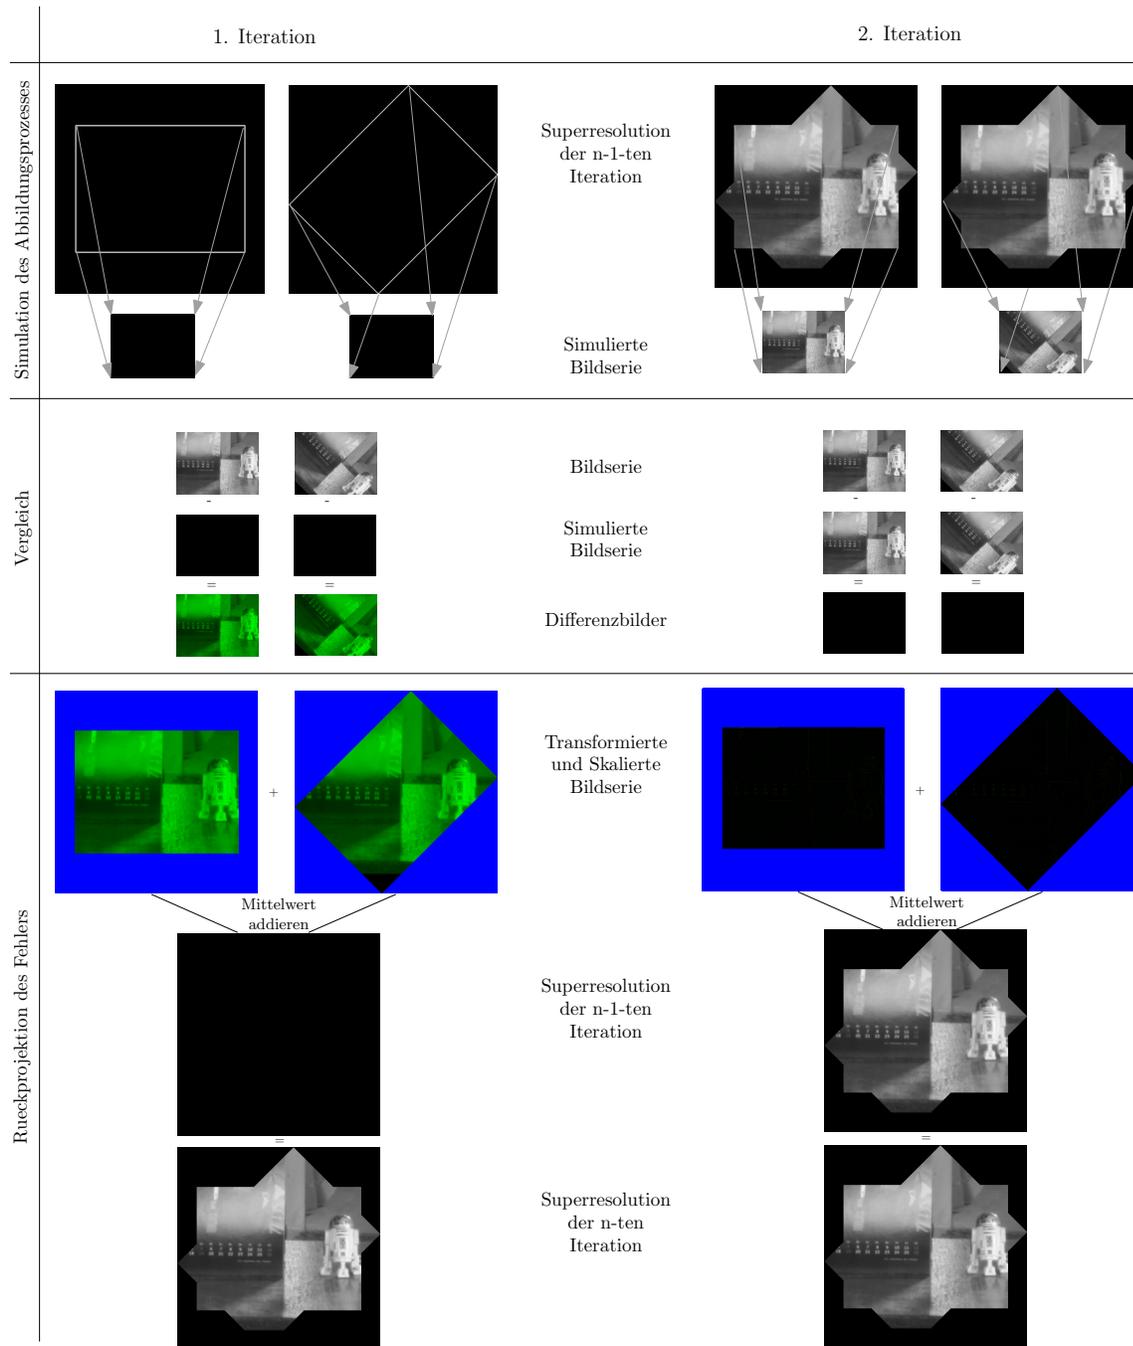


Bild 3.6: 2 IBP Iterationsschritte



# Kapitel 4

## Experimente und Ergebnisse

Es werden verschiedene Experimente durchgeführt, um die vorgestellten Verfahren miteinander zu vergleichen. Wo dies möglich ist, werden die Ergebnisse mit der Ground Truth, dem Bild aus dem die synthetische Bildserie entstanden ist, verglichen (vgl. Kapitel 3.3 zur Erstellung der Testbilder). Der Fehler zur Ground Truth wird als RMS Fehler<sup>1</sup>, dem quadratischen Mittelwert des Fehlers, angegeben. Im Detail wird untersucht, wie sich die Anzahl der Eingangsbilder auf die Qualität der Superresolution und auf das Laufzeitverhalten auswirkt, und wie die Verfahren mit verrauschten und fehlerhaft registrierten Eingangsbildern umgehen.

### 4.1 Fehler zur Ground Truth

In diesem Test wird der Fehler zur Ground Truth bei variierender Anzahl von Eingangsbildern untersucht. Dabei wurden Testreihen mit jeweils 5, 10, 25 und 50 Bildern durchgeführt.

Wie in Abbildung 4.1 zu sehen ist, können die statistischen Verfahren von einer steigenden Anzahl von Eingangsbildern nicht profitieren. Lediglich IBP kann den Fehler zur Ground Truth signifikant verringern, stagnierte in den Tests jedoch ab einer bestimmten Anzahl

---

<sup>1</sup>Root Mean Square:  $x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x^2}$

von Bildern genauso wie die anderen Verfahren.

Im direkten Vergleich (siehe Abb. 4.2) ist bei 2-facher Vergrößerung die Überlegenheit des IBP-Verfahrens über die einfacheren statistischen Verfahren deutlich zu erkennen, lediglich GMRF kann bei leicht geringerer Schärfe zu IBP aufschließen. Beide Methoden scheinen bei gleicher Skalierung feiner aufgelöst zu sein als ML, der quadratische und der Gradienten Prior. Dies tritt besonders an den Umrissen des Kopfes zutage.

Bei einer 3-fachen Vergrößerung, die über die Größe der Ground Truth hinausgeht, zeigen sich die Schwächen einiger Verfahren recht deutlich. Bei ML sind die Ansätze des für dieses Verfahren typischen Schachbrettmusters zu erkennen, welches auch beim Gradienten Prior zum Vorschein tritt. Allerdings treten zusätzlich Fehlpixel auf, die aus fälschlicherweise gefundenen Kanten des Gradientenbildes stammen. Bei Bildern, in denen starke Kanten gefunden werden, kann es vorkommen, dass das Gradientenbild leicht durchscheint. Ein ideales Gradientenbild zu finden, welches in allen Situationen gut funktioniert und die Kanten nicht zu sehr verstärkt, stellt hier die Herausforderung dar. Der Quadratische Prior verliert leicht an Kontrast, wahrscheinlich eine Folge der Unkorreliertheit der Pixel in den getroffenen Bildannahmen. IBP und der GMRF Prior sind wieder als qualitativ besser einzustufen, da sie feiner aufgelöst scheinen und wie der Quadratische Prior keine Fehlpixel oder Artefakte aufweisen.

Bei beiden Skalierungen wird die Überlegenheit der SR Verfahren gegenüber der kubischen Interpolation eines Einzelbildes deutlich, was sich in einer höheren Schärfe und stärkerem Kontrast zeigt.

## 4.2 Laufzeitverhalten

Unter der Voraussetzung, dass die M-Matrizen (siehe Kapitel 3.6.1) der statistischen Verfahren vorberechnet sind, ergibt sich bei ihnen eine nahezu konstante Laufzeit. Hauptverantwortlich für den, wenn auch geringen, Anstieg der Laufzeit ist zum einen das Erstellen des Durchschnittsbildes, das bei allen Verfahren als initiale Schätzung verwendet wird, und zum anderen das Anwenden der Transformationen bei der Erstellung der ROI. Da beides von der Anzahl der Eingangsbilder abhängig ist. Des Weiteren kommt je nach

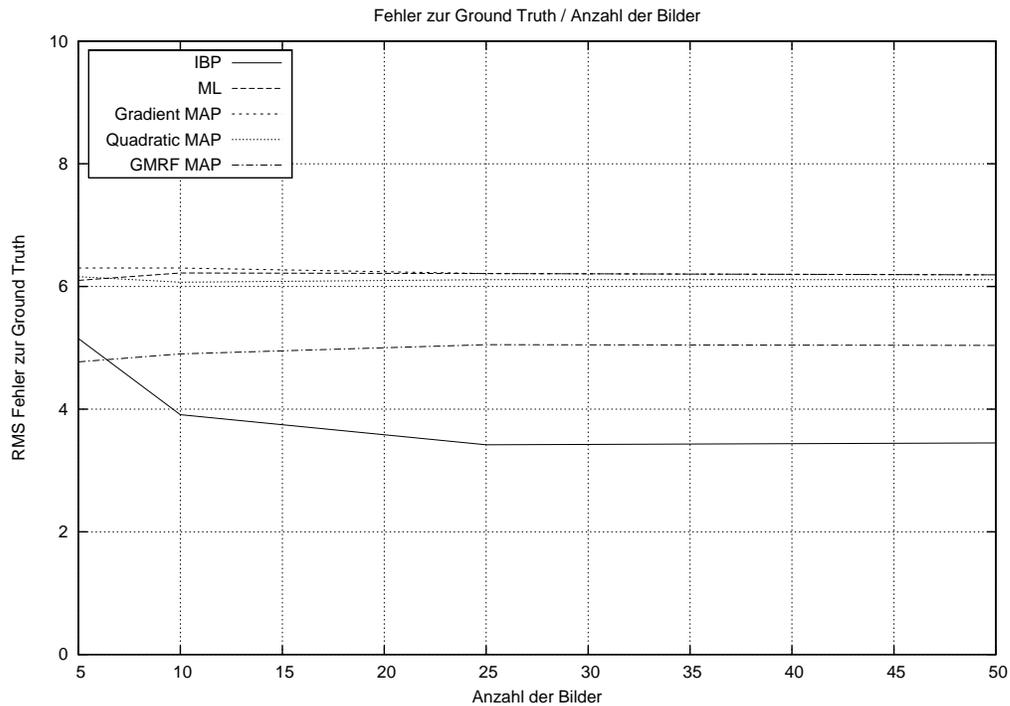


Bild 4.1: RMS Fehler zum Ground Truth (Skalierungsfaktor = 2.0,  $\sigma = 0.8$ )

Verfahren noch die eine oder andere Vorberechnung hinzu, die jedoch hinsichtlich ihrer Auswirkungen auf die Laufzeit vernachlässigbar sind.

IBP weist erwartungsgemäß ein lineares Laufzeitverhalten auf. Da bei der doppelten Anzahl an Eingangsbildern auch doppelt so viele Bilder simuliert und rückprojiziert werden müssen, führt dies zu einer Verdoppelung der Laufzeit.

Wenn es vorteilhaft ist, mehr Eingangsbilder zu verwenden, wie bei verrauschten Eingangsbildern (siehe Kapitel 4.3), so liegt es nahe auf statistische Methoden zurückzugreifen, vor allem, da die statistischen Verfahren bei verrauschten Eingangsbildern insgesamt besser abschneiden.

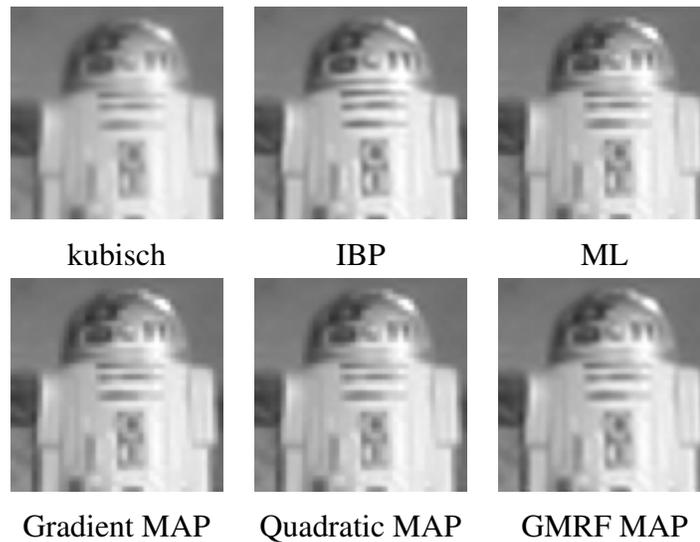


Bild 4.2: Alle Verfahren im Überblick, als Referenz links oben  $2\times$  kubisch interpoliert (Skalierung  $2\times$ ,  $\sigma = 0.8$ , 50 Bilder)

### 4.3 Rauschen

Die Untersuchung der Rauschabhängigkeit hat ergeben, dass die statistischen Verfahren insgesamt robuster gegenüber Rauschen sind als IBP (siehe Abb. 4.7). Wie robust vor allem das Durchschnittsbild gegenüber Rauschen ist, zeigt sich deutlich in Abbildung 4.5. Dies erklärt die guten Ergebnisse des quadratischen Priors, der sich die Eigenschaften des Durchschnittsbildes zu Nutzen macht, indem er es als Mittelwert des gaußverteilten Bildes verwendet (vgl. Abb. 4.5 und Abb. 4.6).

Alle Verfahren profitieren von einer höheren Anzahl an Eingangsbildern in ähnlichem Maße (siehe Abb. 4.6). Der Abstand zwischen den statistischen Verfahren und IBP ist konstant. Interessant ist noch, dass der GMRF Prior mit steigender Bilderzahl zum quadratischen Prior aufschließen und ihn gar überholen kann. Eine Erklärung ist, dass bei steigender Anzahl der Eingangsbilder das Rauschen eine zunehmend kleinere Rolle spielt und die Überlegenheit des GMRF Priors zum tragen kommt.

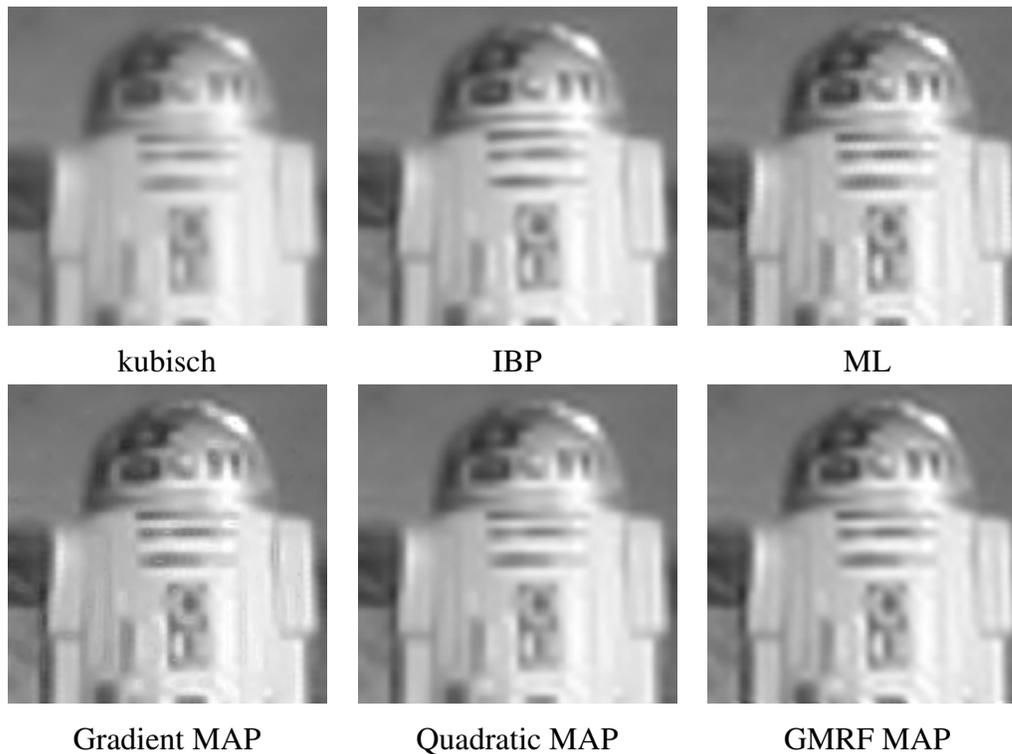


Bild 4.3: Alle Verfahren im Überblick, als Referenz links oben  $3\times$  kubisch interpoliert (Skalierung  $3\times$ ,  $\sigma = 1.4$ , 50 Bilder)

## 4.4 Registrierungsfehler

Um den Registrierungsfehler zu simulieren, wurde auf die ideale Registrierung der synthetischen Bildserie Gaußrauschen mit unterschiedlichem  $\sigma$  addiert. Um die Ergebnisse repräsentativer zu machen, wurden jeweils 10 Durchläufe zu einem Durchschnittswert zusammengefasst.

Die Verfahren reagieren alle recht empfindlich auf Registrierungsfehler, indem die Ergebnisse schnell Unschärf werden. IBP büßt hier bei steigendem Fehler seinen qualitativen Vorsprung den statistischen Verfahren gegenüber ein. Alle Verfahren profitieren von einer höheren Anzahl an Eingangsbildern, allerdings nicht ganz so stark, da sich der Anteil an richtigen Bildinformationen nicht in dem Ausmaß erhöht wie es beispielsweise bei zusätz-

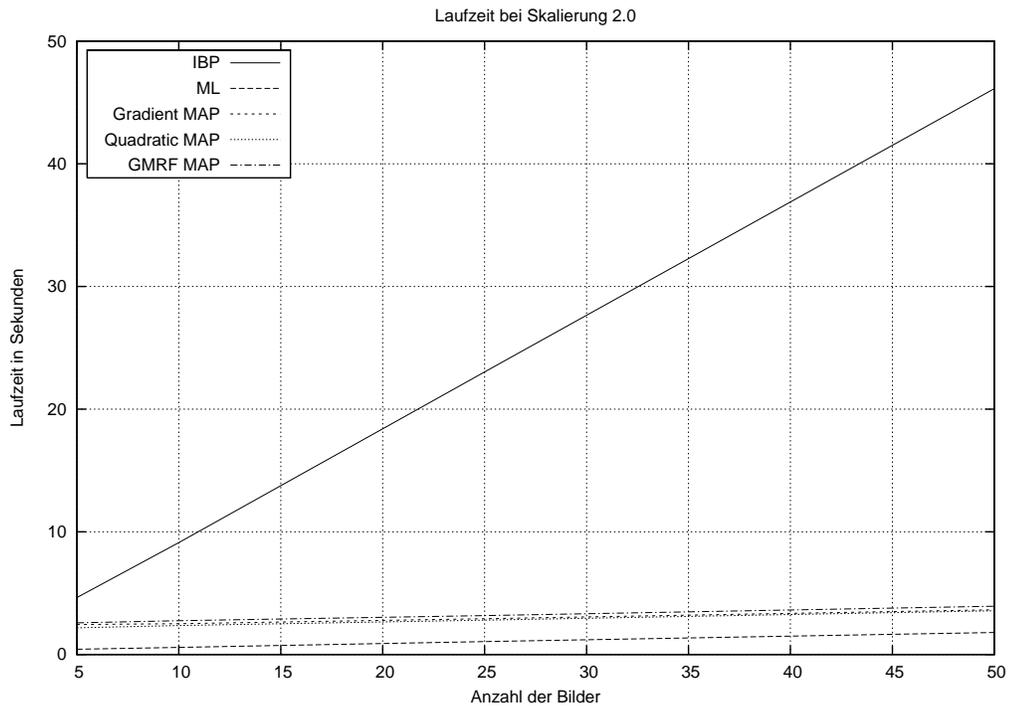


Bild 4.4: Laufzeit (Skalierungsfaktor = 2.0,  $\sigma = 0.8$ )

lichen verrauschten Bildern der Fall ist.

## 4.5 Reale Bildserie

Die reale Testreihe wurde mit einer auf einem Stativ befestigten Canon EOS 400D erstellt. Die 50 Fotos wurden jeweils mit leichtem Versatz aufgenommen, mit einer direkten (Keren) und einer merkmalsbasierten Methode registriert und mit den Verfahren der Super-resolution in der Auflösung erhöht. Es wurden 3 Bereiche ausgewählt (siehe Abb. 4.11), die Potential für eine Auflösungserhöhung bieten. Die Ergebnisse der beiden Registrierungsmethoden weisen nur marginale Unterschiede auf und sind qualitativ nicht zu unterscheiden (vgl. Abb. 4.12). Da die Registrierungsmethoden vergleichbar gute Ergebnisse geliefert haben und die SR Ergebnisse ebenfalls sehr ähnlich sind, liegt die Vermutung

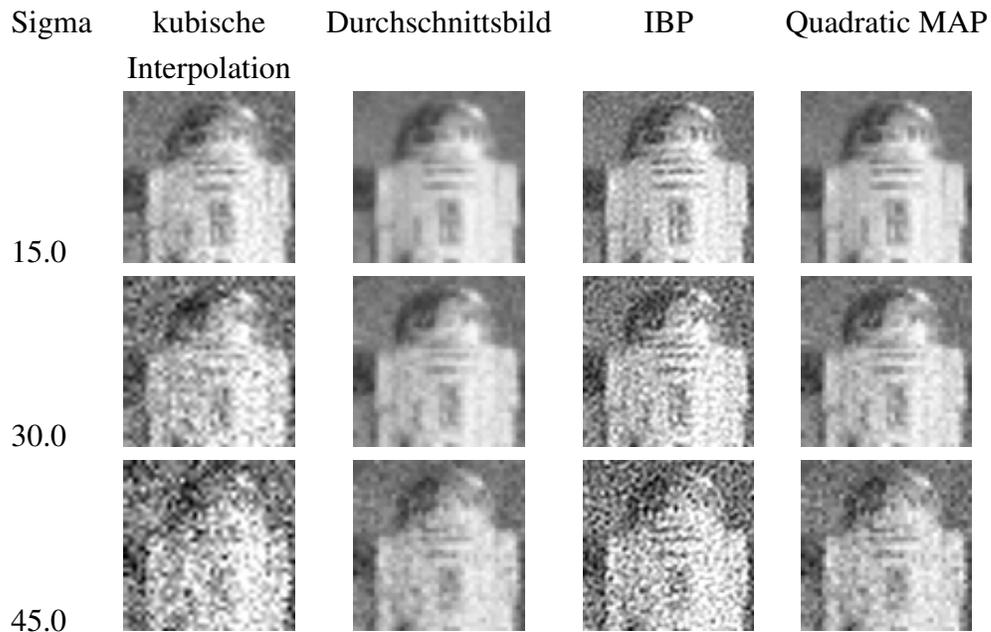


Bild 4.5: Verhalten bei unterschiedlich verrauschten Eingangsbildern

nahe, dass die Wahl der Registrierungsmethode von den Bildeigenschaften (Gibt es Helligkeitsunterschiede? Sind regelmäßige Strukturen im Bild?) abhängig gemacht werden sollte und weniger vom SR Verfahren. Deshalb sind alle Beispielbilder in Abb. 4.13, 4.14 und 4.15 wegen der besseren Vergleichbarkeit mit der direkten Methode registriert. Die „Ground Truth“ wurde aus einem mit ca. 6-facher realer Auflösung aufgenommen und mit kubischer Interpolation auf den Skalierungsfaktor 2 gebracht. Sie ist nicht als echte Ground Truth verwendbar, da Bildausschnitt, Beleuchtung und Bildwinkel nicht völlig übereinstimmen und da sie aufgrund der Entstehung qualitativ besser als eine Aufnahme mit 2-facher realer Auflösung ist.

Im ersten Bereich ist der Schriftzug „Wii“ und die Felge des Autos von besonderem Interesse, da hier die meisten Details wiederhergestellt werden können. Verglichen mit der kubischen Interpolation und den Durchschnittsbildern sind deutlich mehr Details zu erkennen. Bei der Felge sind einzelne Speichen zu erkennen und der Schriftzug wird vor allem im Vergleich zur kubischen Interpolation deutlich lesbarer und schärfer.

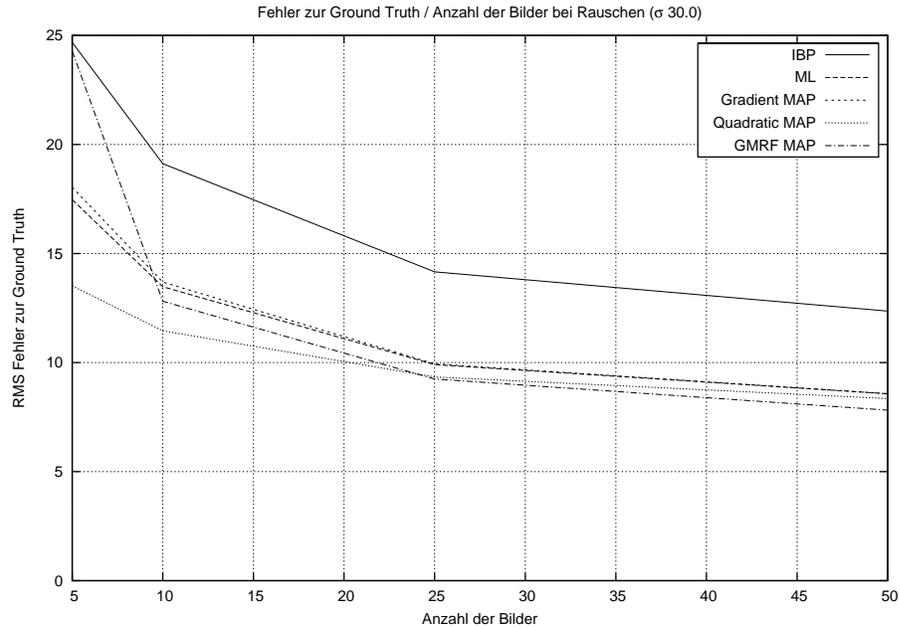


Bild 4.6: Einfluss der Anzahl der Eingangsbilder auf die Rauschabhängigkeit ( $\sigma = 30.0$ )

Im zweiten Bereich ist vor allem der Kartenrücken mit vielen kleinen Details interessant. Im Vergleich zur kubischen Interpolation und den Durchschnittsbildern zeigen sich hier nur unwesentlich mehr Details, die vorhandenen werden aber schärfer abgebildet.

Auch im dritten Bereich werden nur unwesentlich mehr Details sichtbar, das SR Ergebnis zeigt aber schärfere Konturen.

Wie nach den Testergebnissen der synthetischen Bildserie nicht anders zu erwarten, schneiden in allen Bereichen IBP und MAP mit GMRF Prior am besten ab. Insgesamt haben die SR Ergebnisse eine höhere Schärfe.

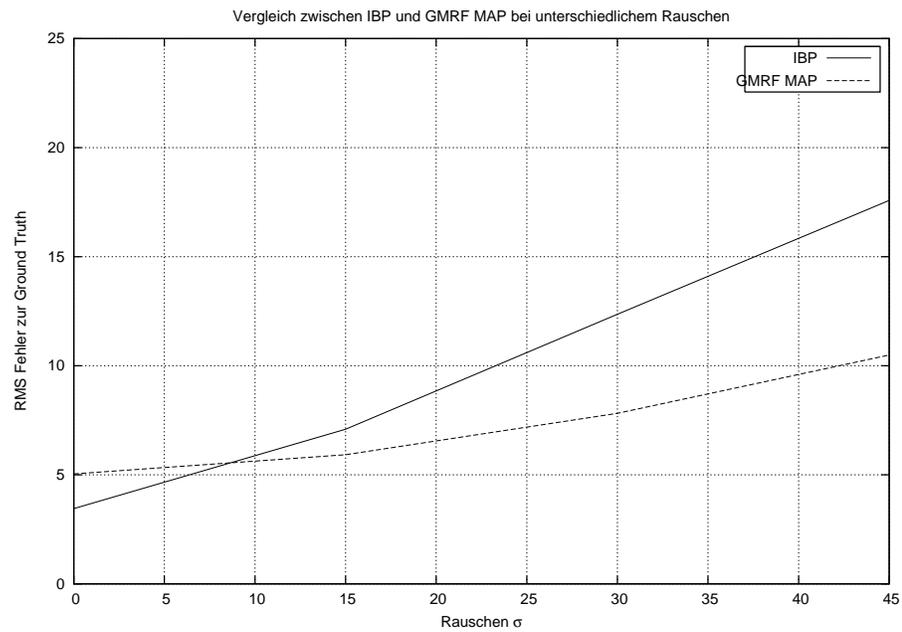


Bild 4.7: Vergleich zwischen IBP und GMRF MAP bei unterschiedlichem Rauschen

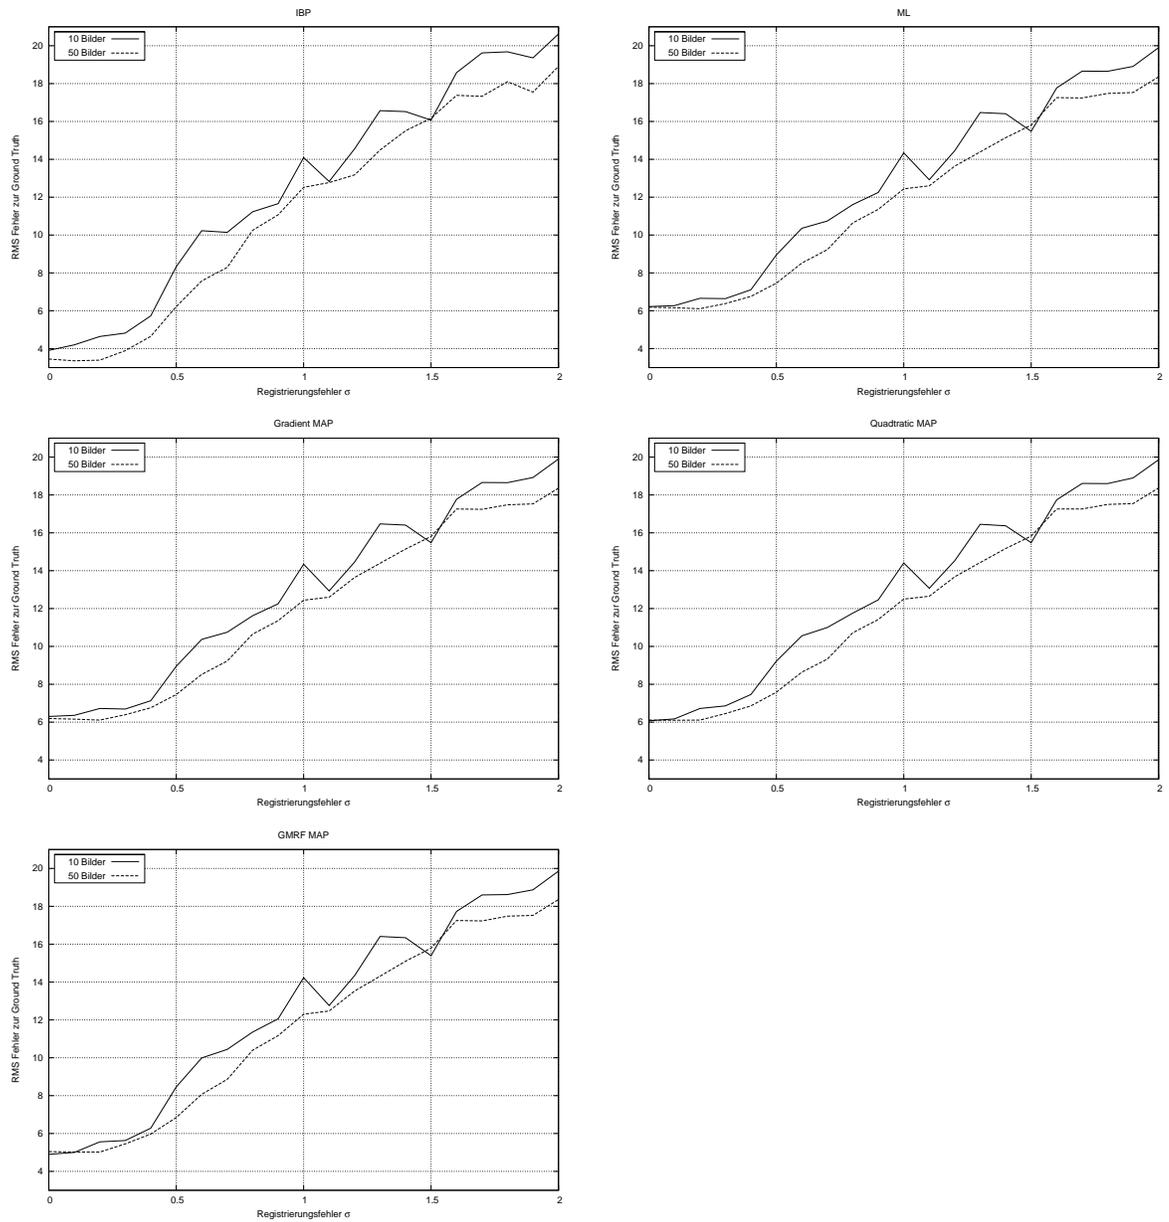


Bild 4.8: Registrierungsfehler aller Verfahren mit 10 und 50 Bildern (je 10 Durchläufe)

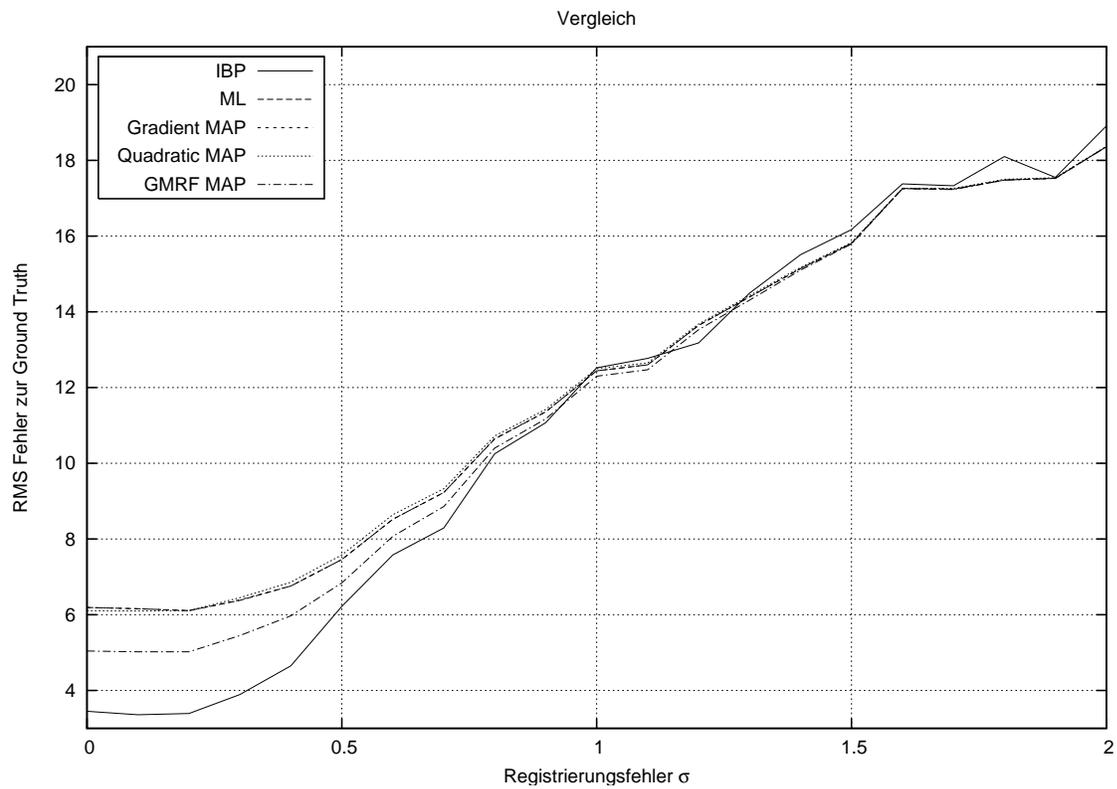


Bild 4.9: Vergleich aller Methoden bei 50 Bildern (je 10 Durchläufe)

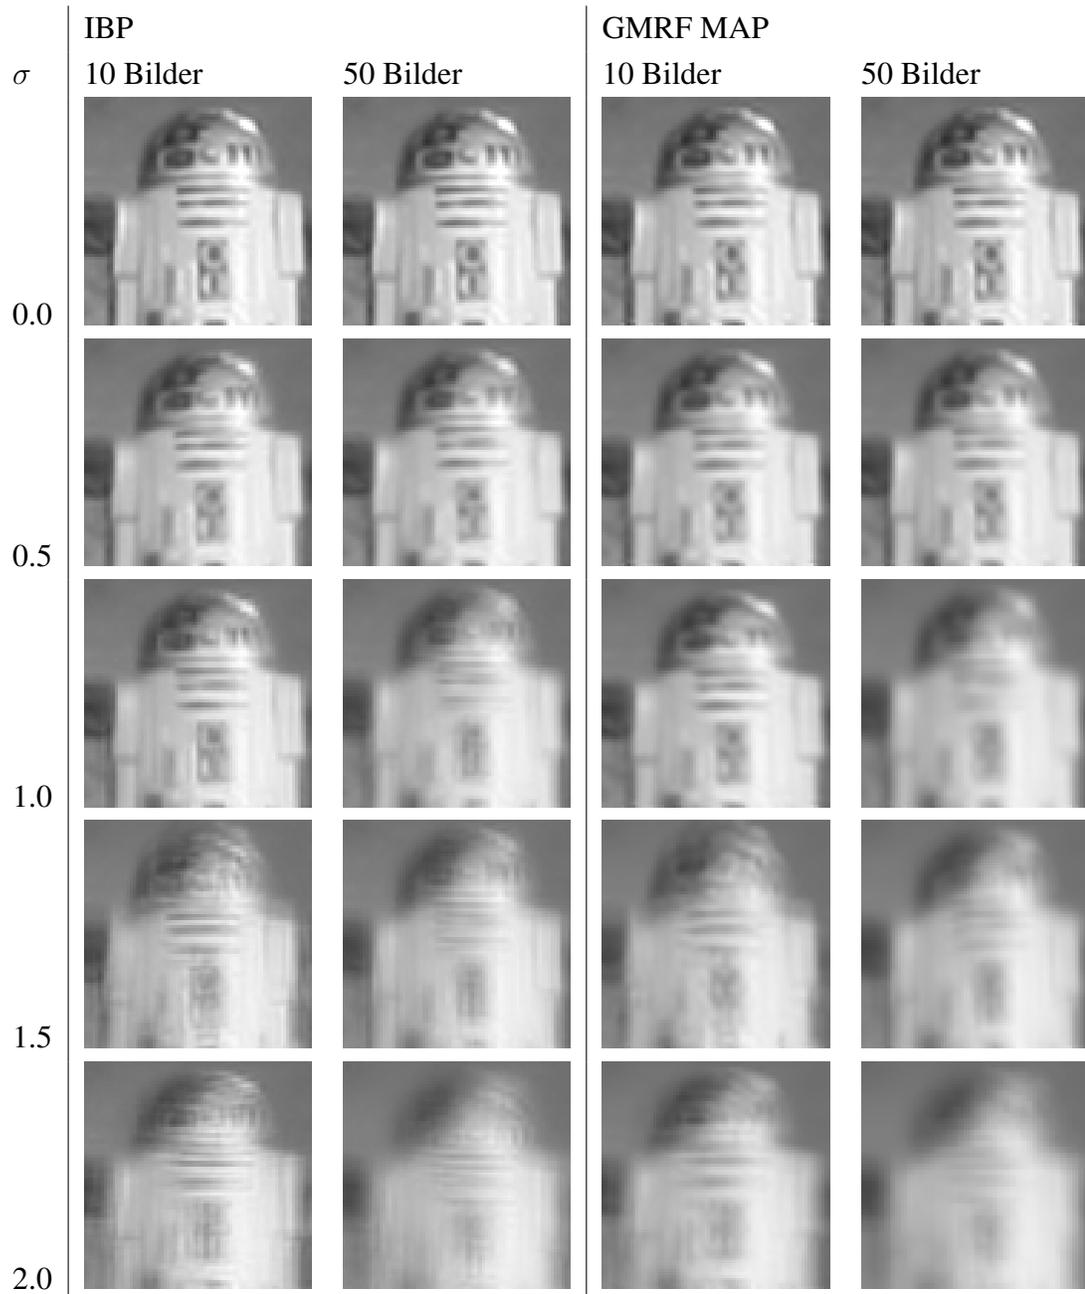


Bild 4.10: Registrierungsfehler

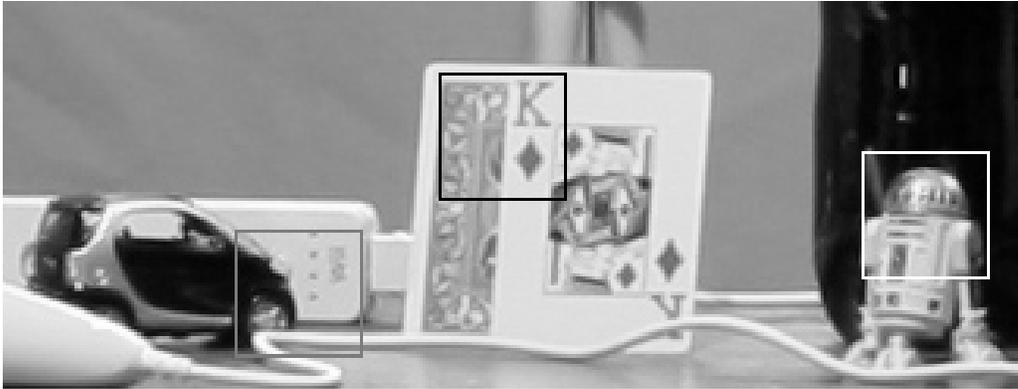


Bild 4.11: Ein Bild der Bildserie, die Markierungen entsprechen den ROI der SR Bilder

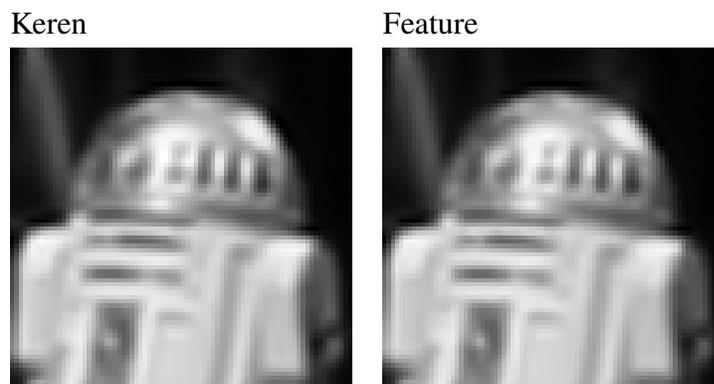
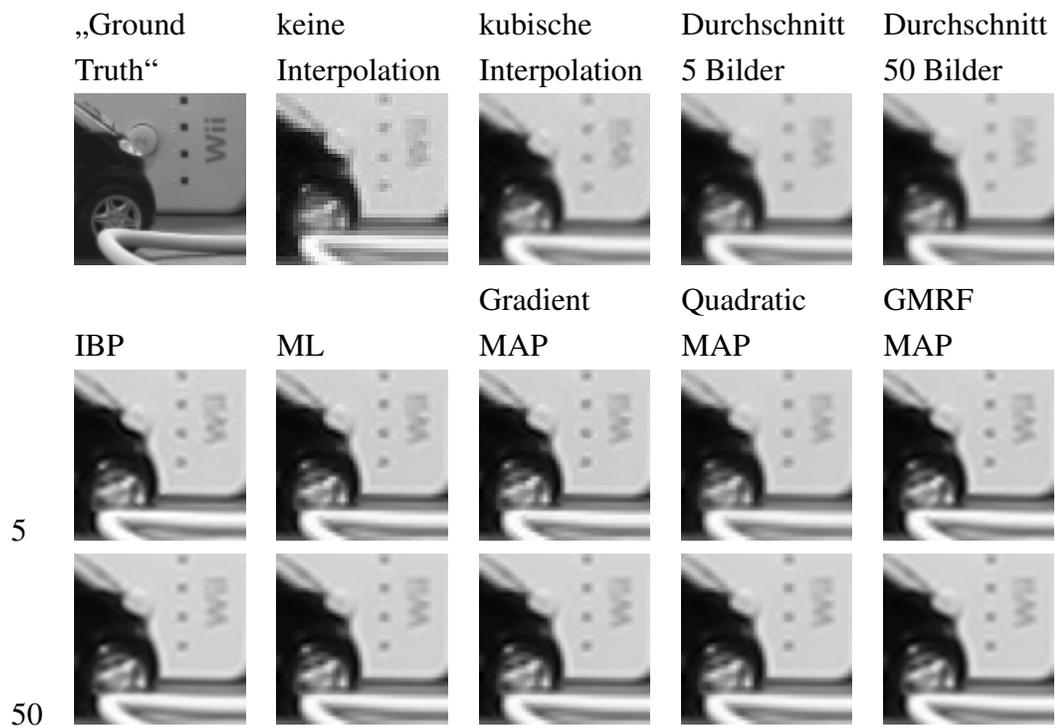
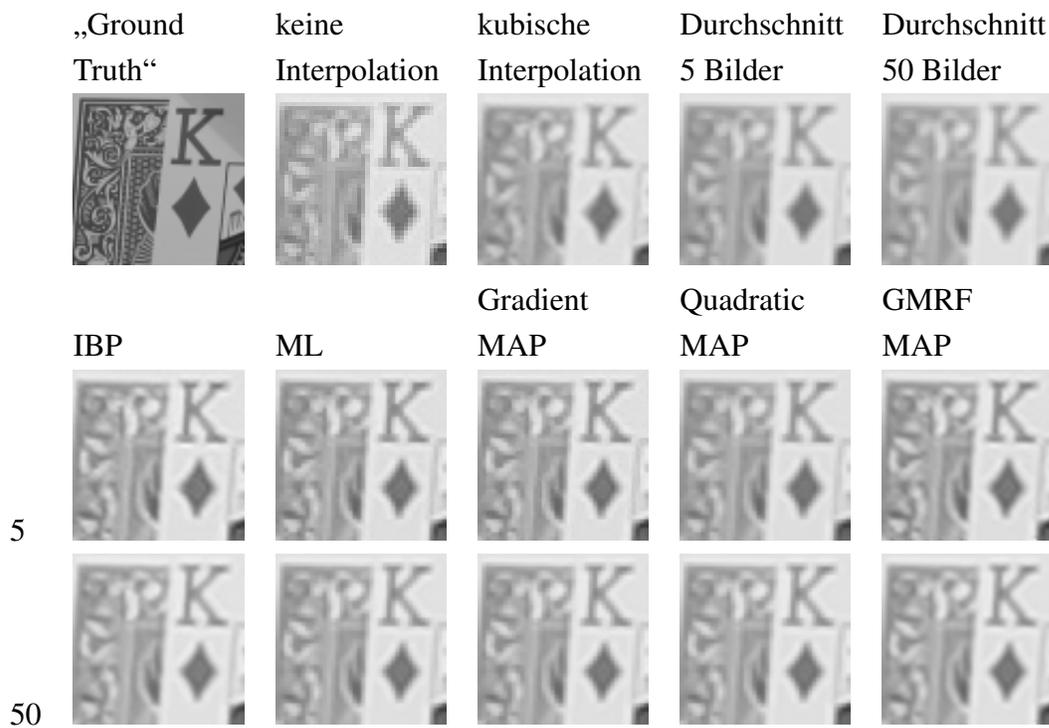
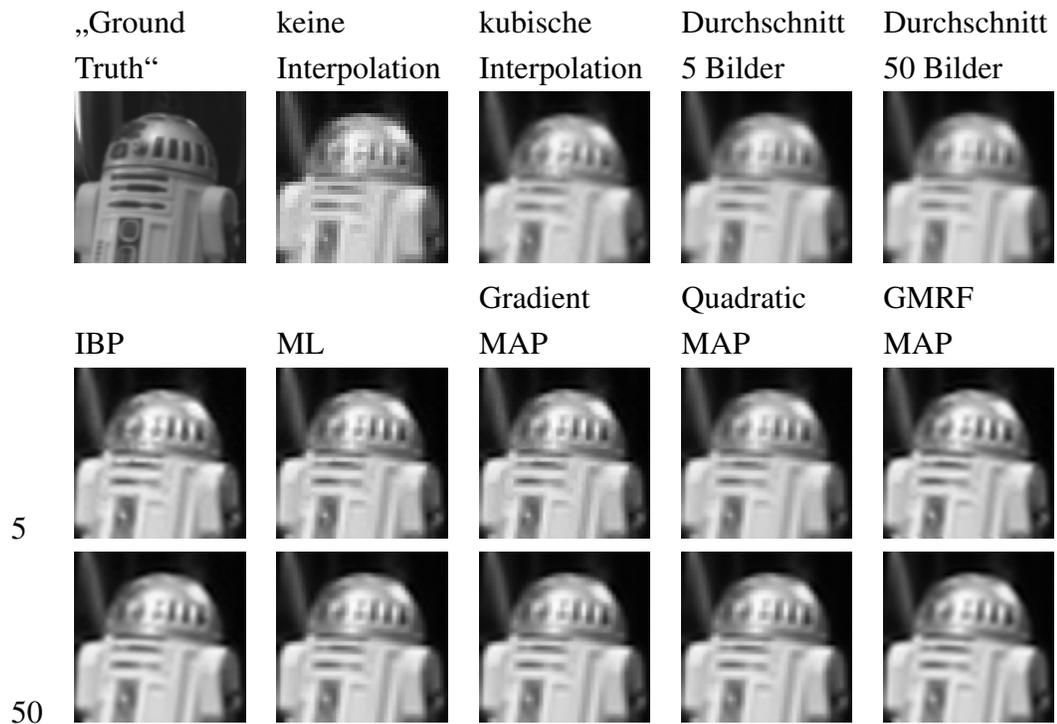


Bild 4.12: SR MAP (GMRF), Links: mit direkter Methode registriert (Keren), Rechts: mit merkmalsbasierter Methode registriert (Skalierung  $2\times$ ,  $\sigma 0.8$ )

Bild 4.13: Bereich 1: Skalierung  $2\times$ ,  $\sigma$  0.8, registriert mit Keren

Bild 4.14: Bereich 2: Skalierung  $2\times$ ,  $\sigma$  0.8, registriert mit Keren

Bild 4.15: Bereich 3: Skalierung  $2\times$ ,  $\sigma$  0.8, registriert mit Keren

# Kapitel 5

## Zusammenfassung

In dieser Studienarbeit wurden mehrere Verfahren zur Superresolution, die zwei unterschiedlichen Ansätzen zuzuordnen sind, implementiert und miteinander verglichen. IBP, ein Verfahren, welches der Tomographie ähnelt, stellt den klassischen Ansatz der Superresolution dar. Die statistischen Verfahren, die die Bilder als aus einem statistischen Prozess entstandenen verstehen, stellen einen neueren Ansatz dar und müssen sich gegenüber dem etablierten IBP behaupten.

Nachdem in Kapitel 2 die wichtigsten Ansätze vorgestellt, und die zu implementierenden Verfahren in den Kontext weiterer Verfahren gestellt wurden, folgt in Kapitel 3 das grundsätzliche Vorgehen bei der Superresolution und eine Erläuterung der zu implementierenden Verfahren im Speziellen.

IBP folgt dem einfachen Schema: den Abbildungsprozess zu simulieren, die simulierte mit der echten Bildserie zu vergleichen und anschließend den Fehler auf die aktuelle SR Schätzung rückzuprojizieren. Genau diese Abfolge gilt es bei der Implementierung einzuhalten, was das lineare Laufzeitverhalten von IBP zur Folge hat. Das Prinzip von IBP ist leicht verständlich und relativ einfach zu implementieren, hat aber den Nachteil keine eindeutigen Lösungen zu produzieren, da es schwer ist, Vorwissen mit einfließen zu lassen.

Bei den statistischen Verfahren hat es sich als äußerst zeitkritisch erwiesen, die Systemmatrix  $M$  vorzuberechnen. Das Erstellen einer sehr großen Systemmatrix (Skalierung 3,

Sigma 1.6) kann beispielsweise mit einem AMD 4000+ durchaus 30-40 Minuten in Anspruch nehmen. Sie kann vorberechnet werden, da die Transformationsmatrix, noch bevor das Gleichungssystem gelöst wird, auf die Bildserie angewandt wird, und sie dadurch nicht mehr von den Eingangsbildern abhängig ist. Sie ist dann nur noch von der Anzahl der Eingangsbilder,  $\sigma$ , dem Skalierungsfaktor und der Größe der ROI abhängig. Dies schränkt den effizienten Einsatz dieser Verfahren auf die vorberechneten Systemmatrizen ein. Capel und Zisserman haben beim Maximum-Likelihood-Verfahren eine starke Rauschanfälligkeit festgestellt. Des Weiteren wurde das SR Bild vor allem ab einem Vergrößerungsfaktor von 1,5 von hochfrequentem Rauschen (in Form eines starken Schachbrettmusters) überlagert (vgl. [CZ03] und [Cap04]). Die Tests in Kapitel 4 konnten dies jedoch nur bedingt bestätigen. Hier zeigen sich erst ab einer Skalierung von 3 die Ansätze eines Schachbrettmusters (vgl. 4.3).

In Kapitel 4 wurden die Verfahren nach verschiedenen Kriterien miteinander verglichen. Dabei hat sich herausgestellt, dass IBP in Punkto Bildqualität Maßstäbe setzt, zumindest bei kaum verrauschten Eingangsbildern und guter Registrierung. Allerdings stellen viele Eingangsbilder wegen des linearen Laufzeitverhaltens ein Problem dar. Die statistischen Verfahren liefern bei stark verrauschten Eingangsbildern bessere Ergebnisse als IBP. Durch viele Eingangsbilder lassen sich diese noch weiter verbessern. Die bei vorberechneten Systemmatrizen nahezu konstante Laufzeit und ihrer Robustheit bei Rauschen prädestinieren die statistischen Verfahren für solche Bildserien.

Ungenau registrierte Eingangsbilder wiederum führen bei allen Verfahren zu unscharfen Ergebnissen. Da IBP bei steigendem Registrierungsfehler seinen qualitativen Vorsprung einbüßt und eine höhere Anzahl an Eingangsbildern das Ergebnis verbessert, sollte ein statistisches Verfahren eingesetzt werden, wenn genügend Eingangsbilder zur Verfügung stehen.

Zusammenfassend lässt sich sagen, dass bei wenigen, rauscharmen Eingangsbildern IBP vorzuziehen ist, da es qualitativ bessere Ergebnisse bei vergleichbarer Laufzeit bietet. Vor allem bei stark verrauschten und ungenau registrierten großen Bildserien sind die statistischen Verfahren klar überlegen.

# Literaturverzeichnis

- [Cap04] CAPEL, David: *Image Mosaicing and Super-resolution*. Springer, Berlin, Heidelberg, New York, 2004 (Distinguished Dissertations)
- [CZ98] CAPEL, David ; ZISSERMAN, Andrew: Automated mosaicing with super-resolution zoom. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*. Washington, DC, USA : IEEE Computer Society, 1998, 885–891
- [CZ03] CAPEL, David ; ZISSERMAN, Andrew: *Computer vision applied to super resolution*. [citeseer.ist.psu.edu/capel03computer.html](http://citeseer.ist.psu.edu/capel03computer.html). Version: 5 2003
- [EF97] ELAD, Michael ; FEUER, Arie: Restoration of a single superresolution image from several blurred, noisy, and undersampled measured images. In: *IEEE Transactions on Image Processing* 6 (1997), 12, Nr. 12, S. 1646–1658
- [EST97] EREN, P. E. ; SEZAN, M. I. ; TEKALP, A. M.: Robust, object-based high-resolution image reconstruction from low-resolution video. In: *IEEE Transactions on Image Processing* 6 (1997), Nr. 10
- [IP91] IRANI, Michal ; PELEG, Shmuel: Improving resolution by image registration. In: *Graph. Models Image Process.* 53 (1991), Nr. 3, 231-239. [http://www.wisdom.weizmann.ac.il/~irani/PAPERS/SR\\_CVGIP91.pdf](http://www.wisdom.weizmann.ac.il/~irani/PAPERS/SR_CVGIP91.pdf)
- [IP93] IRANI, Michal ; PELEG, Shmuel: Motion Analysis for Image Enhancement: Resolution, Occlusion, and Transparency. In: *Journal on Visual Communications*

*and Image Representation* 4 (1993), 12, Nr. 4, 324-335. <http://www.cs.huji.ac.il/~peleg/papers/vcir93-irani.pdf>

- [PST97] PATTI, A. ; SEZAN, M. ; TEKALP, A. M.: Superresolution video reconstruction with arbitrary sampling lattices and nonzero aperture time. In: *IEEE Transactions on Image Processing* (1997). [citeseer.ist.psu.edu/patti97super.html](http://citeseer.ist.psu.edu/patti97super.html)
- [SS96] SCHULTZ, R. ; STEVENSON, R.: Extraction of high-resolution frames from video sequences. In: *IEEE Transactions on Image Processing* (1996). [citeseer.ist.psu.edu/article/schultz96extraction.html](http://citeseer.ist.psu.edu/article/schultz96extraction.html)
- [TH84] *Kapitel* Multiframe image restoration and registration. In: TSAI, Roger Y. ; HUANG, Thomas S.: *Advances in Computer Vision and Image Processing*. JAI Press, 1984, S. 317–339
- [TK96] TOM, B. ; KATSAGGELOS, A.: Resolution enhancement of video sequences using motion compensation. In: *Proceedings of the IEEE International Conference, 1996*
- [UG92] UR, Hanoch ; GROSS, Daniel: Improved resolution from subpixel shifted pictures. In: *CVGIP: Graph. Models Image Process.* 54 (1992), Nr. 2, S. 181–186