Videokompression am Beispiel H.264

Medientechnologie IL

Andreas Unterweger

Vertiefung Medieninformatik und Bildverarbeitung
Studiengang ITS
FH Salzburg

Sommersemester 2023

Menschliche Bewegtbildwahrnehmung

- Gehirn interpretiert Bewegungen durch Helligkeitsänderungen
  - Bewegung eines Objektes bewirkt Bewegung der dazugehörigen (vom Objekt reflektierten) Photonen auf der Netzhaut (den Rezeptoren)
  - Rezeptoren können ca. 10 Änderungen pro Sekunde wahrnehmen
  - Mehr als ca. 16 Änderungen pro Sekunde bewirken Eindruck von Bewegung (schwer von tatsächlicher Bewegung unterscheidbar)

→ Aufeinander folgende Bilder können Bewegtbildeindruck hervorrufen

- Zusätzlich: Nachbildwirkung (**nicht** Ursache für Bewegtbildeindruck)
  - Rezeptoren „leuchten“ ca. 40 ms nach (Reizamplitude klingt ab)

  → Neue und alte Reize überlagern einander → Glättung (Tiefpassfilter)

  → Eindruck (teilweise) „flüssiger“ Bewegung
- Verschiedene Voraussetzungen für tatsächlich „flüssige“ Bewegtbilder:
  `https://www.red.com/red-101/high-frame-rate-video`

Zeitliche Korrelation in Bewegtbildern

- Aufeinander folgende Bilder korrelieren meist stark

→ Ausnutzen durch spezielle Differenzkodierung

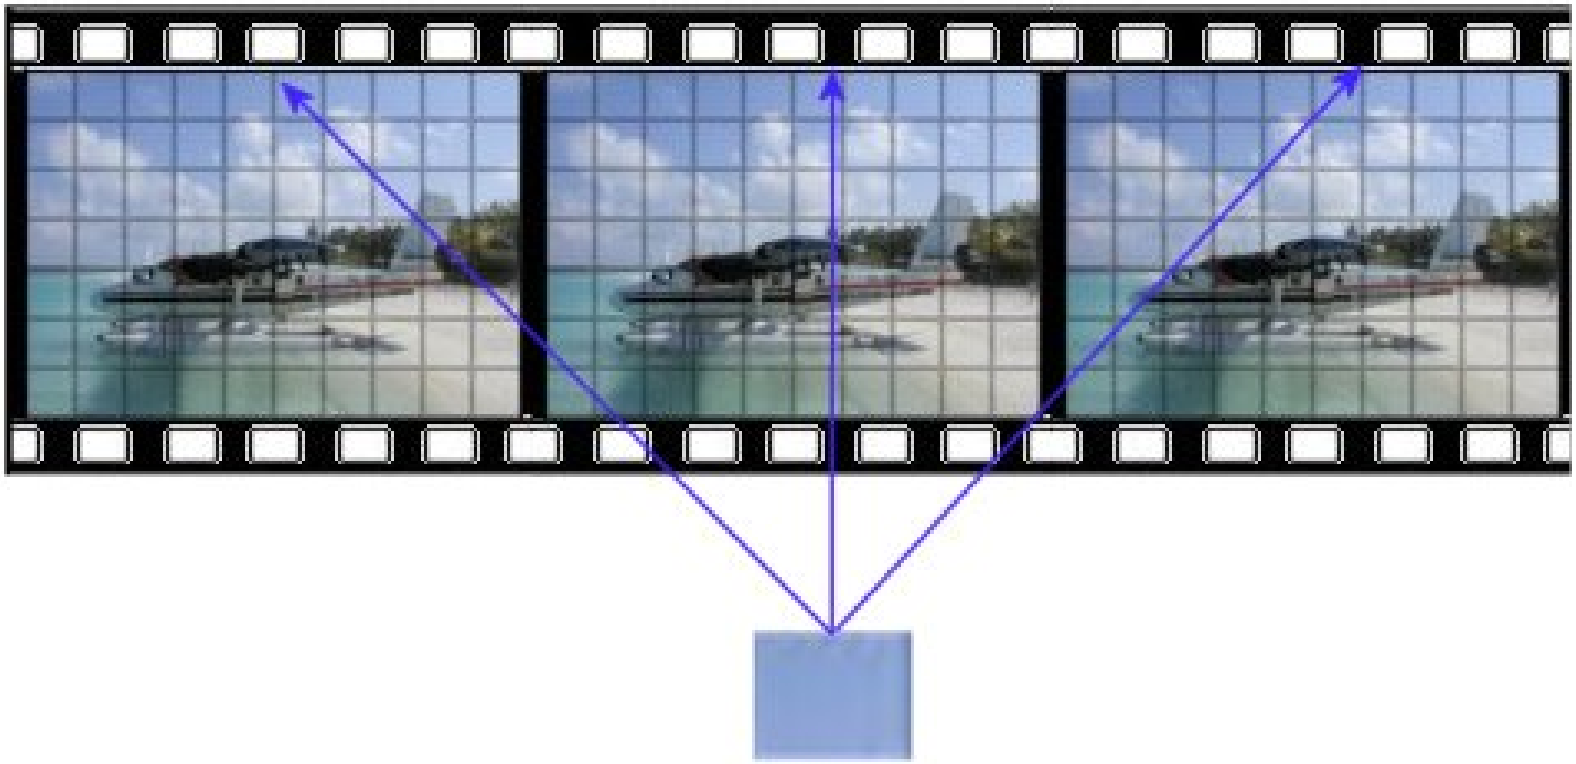

Quelle: `http://www.labdv.com/images/library/dv_basics/mpeg_explained/tempcompress.jpg`

Motion Estimation I

- Bewegungen zwischen Bildern betreffen nicht alle Pixel gleichermaßen
- Pixelweise Bewegungssuche ist zu aufwändig

→ Blockbasierte Bewegungssuche (englisch *Motion Estimation*, ME)

  - Vorgehensweise: Passenden Block suchen (englisch *Block Matching*)
  - Bewegungsvektor (englisch *Motion Vector*): Versatz zwischen Ausgangs- und gefundenem Block (X- und Y-Versatz)
  - Parameter: Suchradius (Fenstergröße)
  - Vergleichsmetrik notwendig (implementierungsabhängig)

- Speicherung: Statt komplettem Block
  - Ein Bewegungsvektor (mit zwei Komponenten)
  - Pixelweise Differenz zwischen Ausgangs- und gefundenem Block (englisch *Block Motion Compensation*, kurz BMC oder MC)

Motion Estimation II

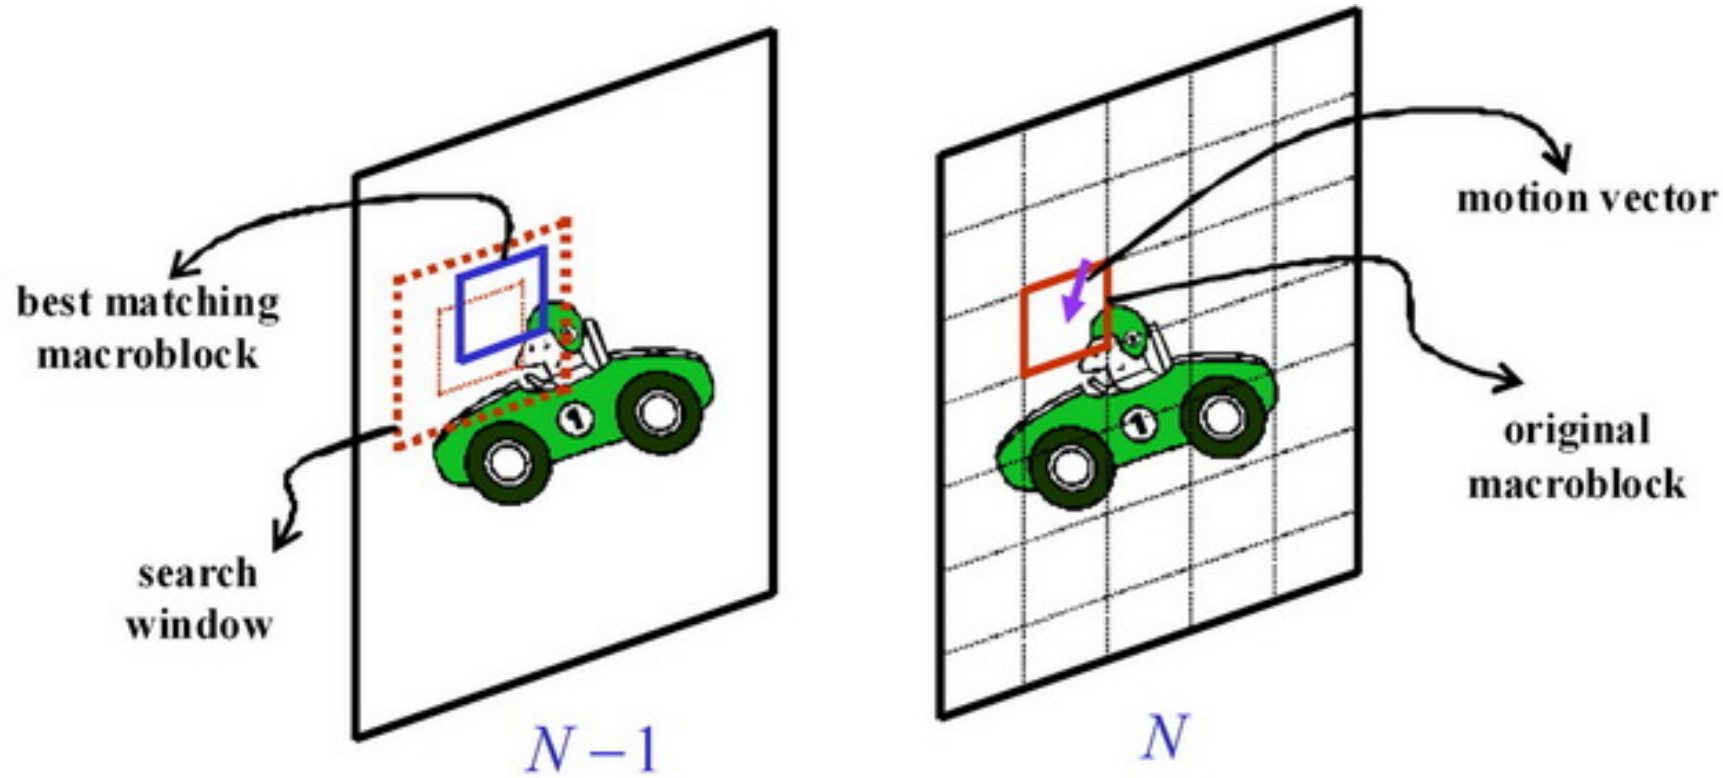

Quelle: `http://www-sipl.technion.ac.il/UploadedFiles/BlockBasedMotionEstimation.jpg`

Blockvergleichsmetriken I

- Summe von Pixeldifferenzen ist keine brauchbare Metrik
  - Vorzeichenverschiedene Differenzen heben sich auf
  - $\rightarrow$ Weißes Rauschen ist quasi immer so gut wie ein perfekter Treffer

$\rightarrow$ Andere Blockvergleichsmetriken notwendig

- Notation:
  - $M, N \in \mathbb{N}^+$: Blockdimensionen in Pixel
  - $m \in \{x \in \mathbb{N} \mid 0 \leq x \leq M-1\}$, $n \in \{x \in \mathbb{N} \mid 0 \leq x \leq N-1\}$
  - $X_{m,n}$: Pixel des Ausgangsblocks
  - $X'_{m,n}$: Pixel des Vergleichsblocks
  - x_{max}: Maximal möglicher Pixelwert (z.B. 255 bei 8 Bit)
  - d_{Metrik}: Differenzwert (Metrikausgabewert)
- Praktische Einschränkung: Nur Pixel des Y-Kanals werden betrachtet
  $\rightarrow X_{m,n}$ und $X'_{m,n}$ sind Zahlen und keine Vektoren

Blockvergleichsmetriken II

- Sum of Absolute Differences (SAD):

$$d_{SAD} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \left| X'_{m,n} - X_{m,n} \right|$$

- Sum of Squared Differences (SSD):

$$d_{SSD} = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \left(X'_{m,n} - X_{m,n} \right)^2$$

Blockvergleichsmetriken III

- Mean Squared Error (MSE):

$$d_{MSE} = \frac{d_{SSD}}{MN} = \frac{1}{MN} \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} \left(X'_{m,n} - X_{m,n} \right)^2$$

- Peak Signal-to-Noise Ratio (PSNR):

$$d_{PSNR} = 10 \log \left(\frac{x_{max}^2}{d_{MSE}} \right) = 20 \log \left(\frac{x_{max}}{\sqrt{d_{MSE}}} \right), \quad [d_{PSNR}] = \text{dB}$$

Praktische Motion Estimation

- Weiterer Parameter: Anzahl zu durchsuchender Vorgängerbilder
- Vorteil: Höhere Effizienz durch möglicherweise bessere Treffer
- Nachteil: Speicherung der Referenzbildnummer notwendig
- Weiterer Nachteil: Lineare Erhöhung der Suchdauer
- Volle Suche ist aufwändig (quadratische Komplexität!)

$\rightarrow$ Nicht alle Möglichkeiten ausprobieren

- Nachteil: Findet eventuell ein lokales Minimum (nicht das globale)
- Dutzende ME-Algorithmen in der Literatur

Überblick: Typischer H.264-Encoder

- Typische Encoder-Architektur (Standard gibt nur Dekodierung vor)

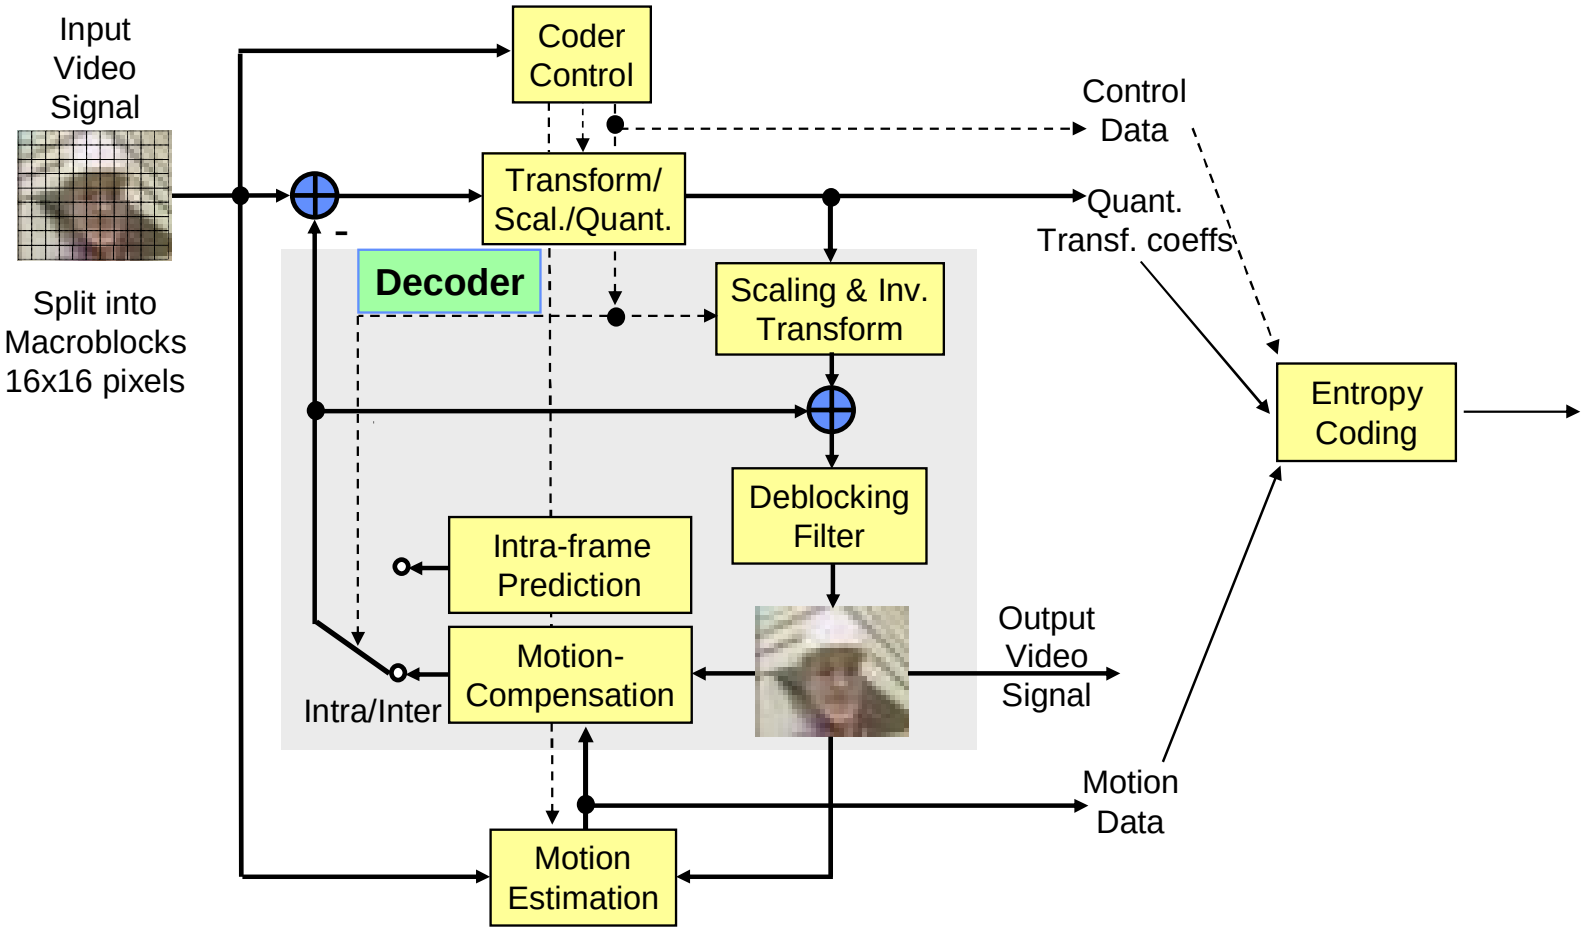

Quelle: Wiegand, T. and Sullivan, G. J.: The H.264 | MPEG-4 AVC Video Coding Standard. `http://ip.hhi.de/imagecom_G1/assets/pdfs/H264_03.pdf`. 2004.

Übersicht Bildtypen

- Vereinfacht: Drei Bildtypen (nach Kodierungsabhängigkeit)
  - **I**ntra: Unabhängig von anderen Bildern
  - **P**rädiziert: Verwendet nur vorangegangene[1] Bilder (MC)
  - **B**idirektional: Verwendet vorangegangene und folgende Bilder (MC)
- Kodierungsentscheidung pro (Makro-)Block ($16 \cdot 16$ Y-Pixel):
  - I-Block: In I-, P- und B-Bildern erlaubt
  - P-Block: In P- und B-Bildern erlaubt
  - B-Block: In B-Bildern erlaubt
- Encoder darf Blocktypen (mit diesen Einschränkungen) frei wählen

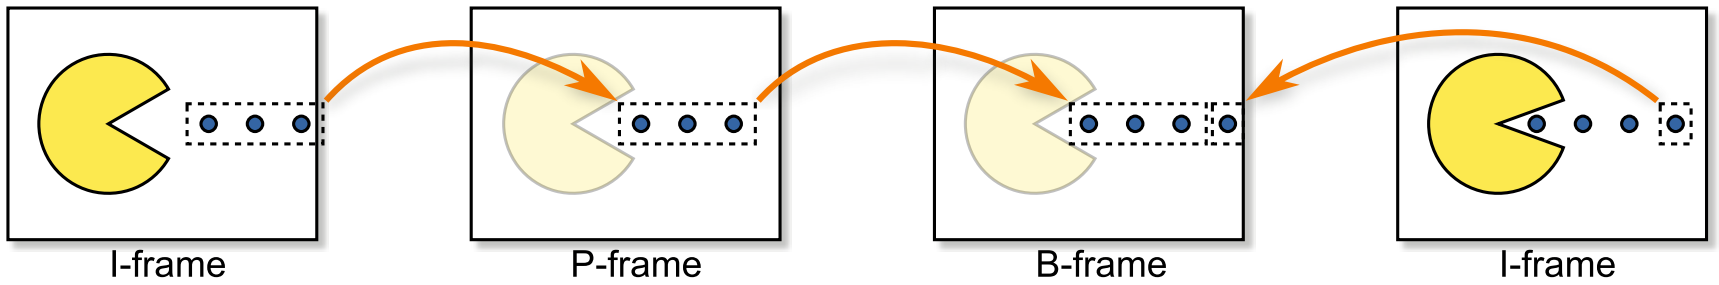

Quelle: `http://en.academic.ru/dic.nsf/enwiki/386020f`

[1] Theoretisch möglich (unüblich): auch folgende Bilder

Besonderheiten bei der Verwendung von B-Frames

- MC aus folgenden („zukünftigen“) Bildern ist unpraktikabel

→ Zum Kodieren Bilder umsortieren → Abweichende Kodierreihenfolge (englisch *Coding Order*); Beispiel: IBBbPBBbP

- Für MC verwendete Bilder müssen zuerst kodiert werden
- Wichtig: Darstellungsreihenfolge (englisch *Display Order*) muss beibehalten werden

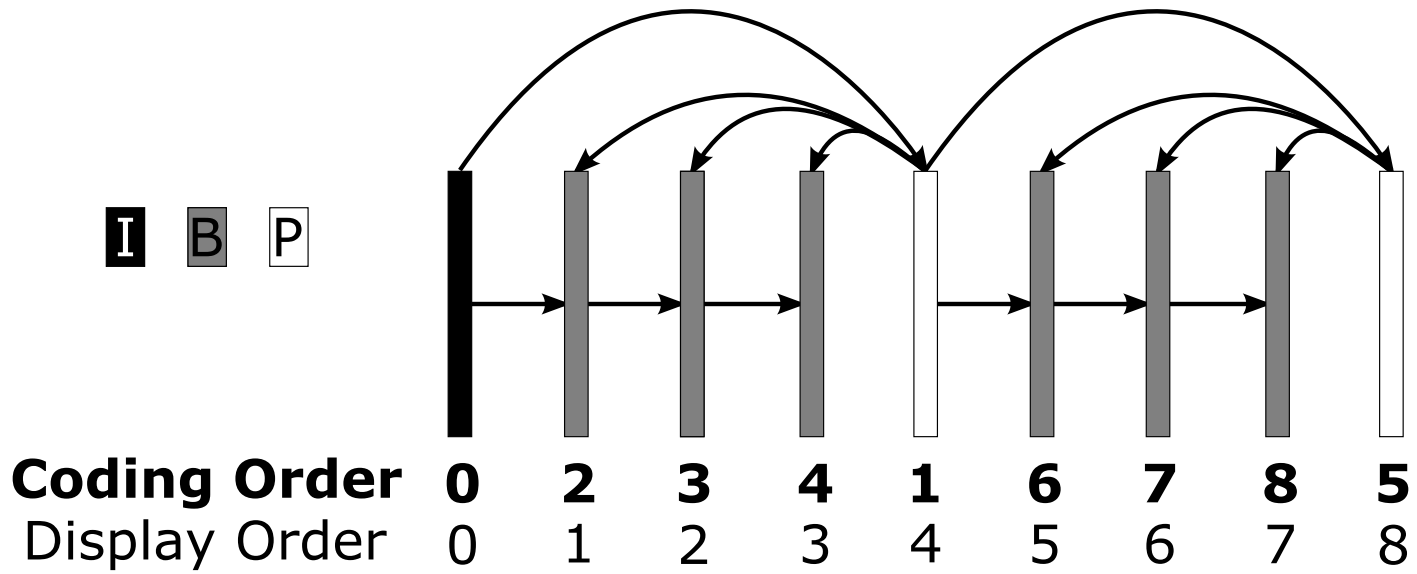

Interprädikation (englisch *Inter Prediction*) I

- Makroblöcke ($16 \cdot 16$ Y-Pixel) können partitioniert werden
- $8 \cdot 8$ Makroblockpartitionen können subpartitioniert werden
- Jede Partition kann auf unterschiedliche Referenzbilder verweisen
- Jede (Sub-)Partition kann unterschiedliche Bewegungsvektoren haben

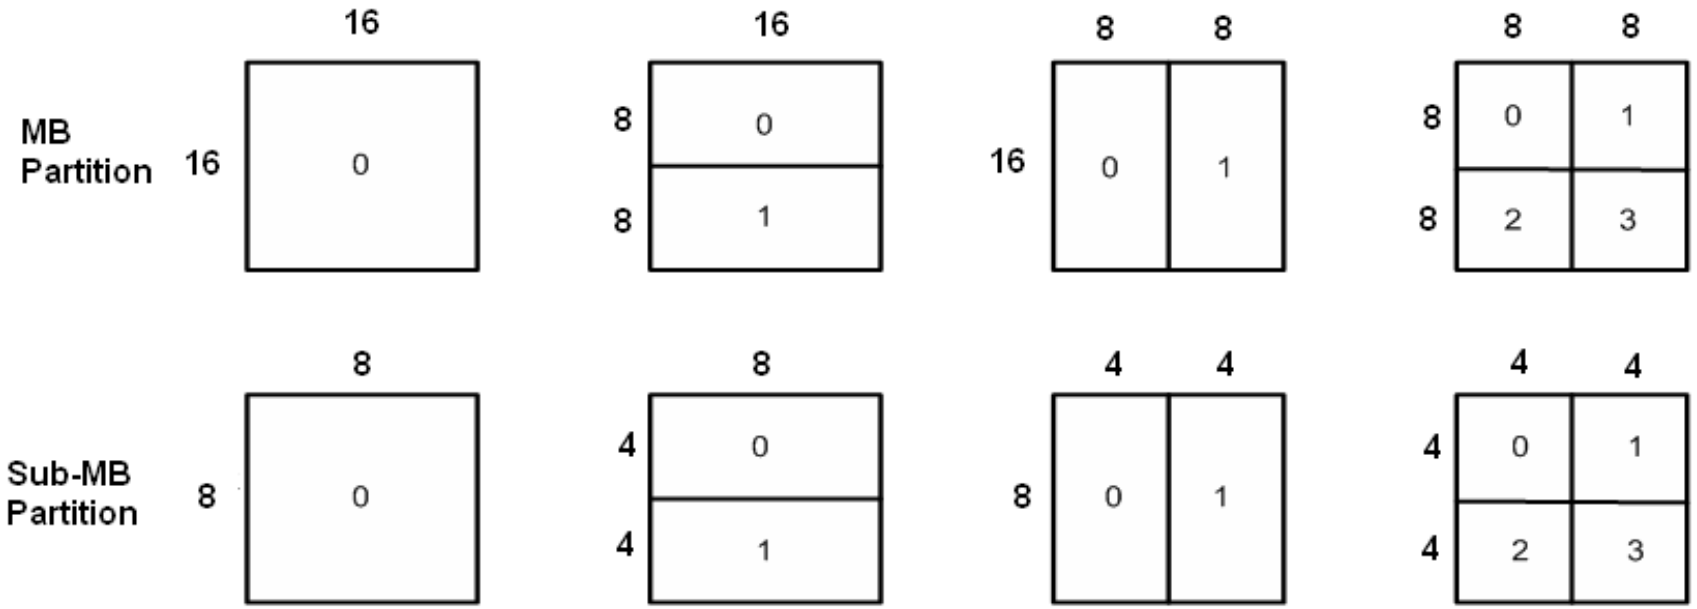

Quelle: Kwon, S., Tamhankar, A. and Rao, K.R.: Overview of H.264 / MPEG-4 Part10. http://www.powershow.com/view/19bc9-NDQyM/Overview_of_H_264_MPEG4_Part10_powerpoint_ppt_presentation. 2004.

Interprädikation (englisch *Inter Prediction*) II

- Subpixelgenauigkeit bei Bewegungsvektoren möglich

→ Interpolation notwendig

  - Realisierung: Interpolationsfilter (ohne Details)
  - 1. Schritt: Pixel an „halben Positionen“ aus Pixeln interpolieren
  - 2. Schritt: Pixel an „Viertel-Positionen“ aus „halben“ interpolieren

→ Weiterer ME-Parameter → Komplexitätserhöhung

→ Praktische Maßnahmen:

  - Schnelle ME-Algorithmen
  - Kleinerer ME-Radius
  - Geringe Anzahl Referenzbilder

- B-Blöcke mitteln **zwei unabhängige** Treffer vor MC

→ Weitere Komplexitätserhöhung

Intraprädikation (englisch *Intra Prediction*) I

- I-Block-Kodierung ähnlich wie in JPEG (mit Verbesserungen)
- Wahl: 1 $16 \cdot 16$-Block oder 16 $4 \cdot 4$-Blöcke (später $8 \cdot 8$ ergänzt)
- Blöcke werden aus Nachbarblöcken extrapoliert $\rightarrow$ Differenzkodierung
- Extrapolationsrichtung pro Block wählbar (neun Modi bei $4 \cdot 4$)

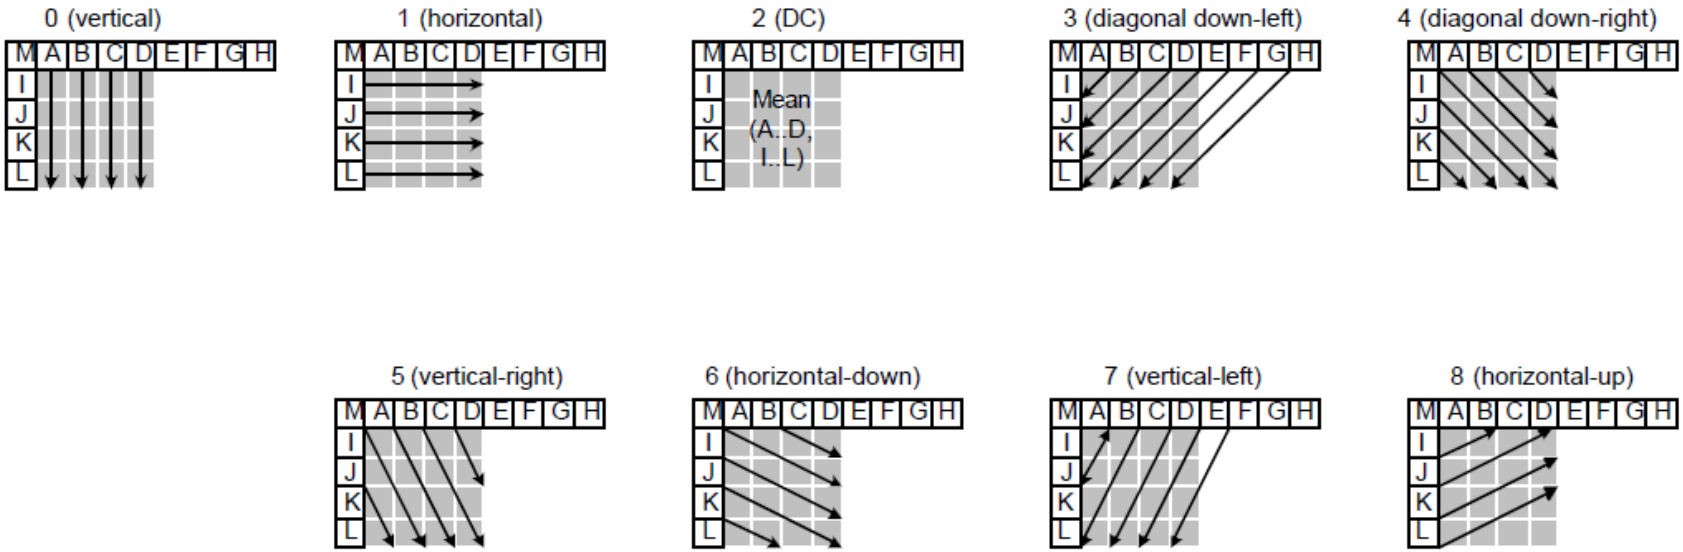

Quelle: Richardson, I. E. G.: H.264 / MPEG-4 Part 10: Intra Prediction. `http://www.vcodex.com/h264.html`. 2003.

Intraprädikation (englisch *Intra Prediction*) II

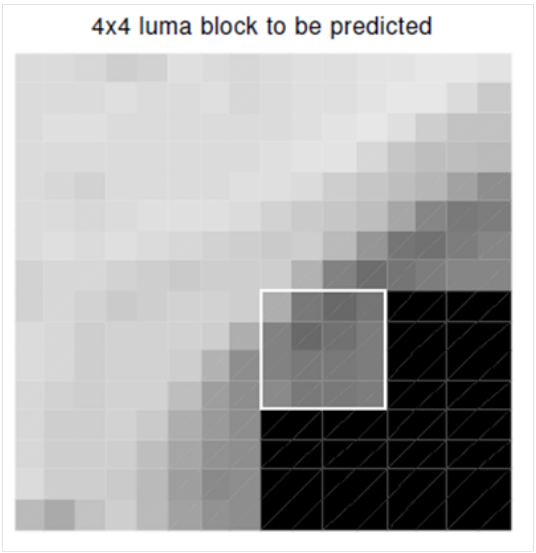

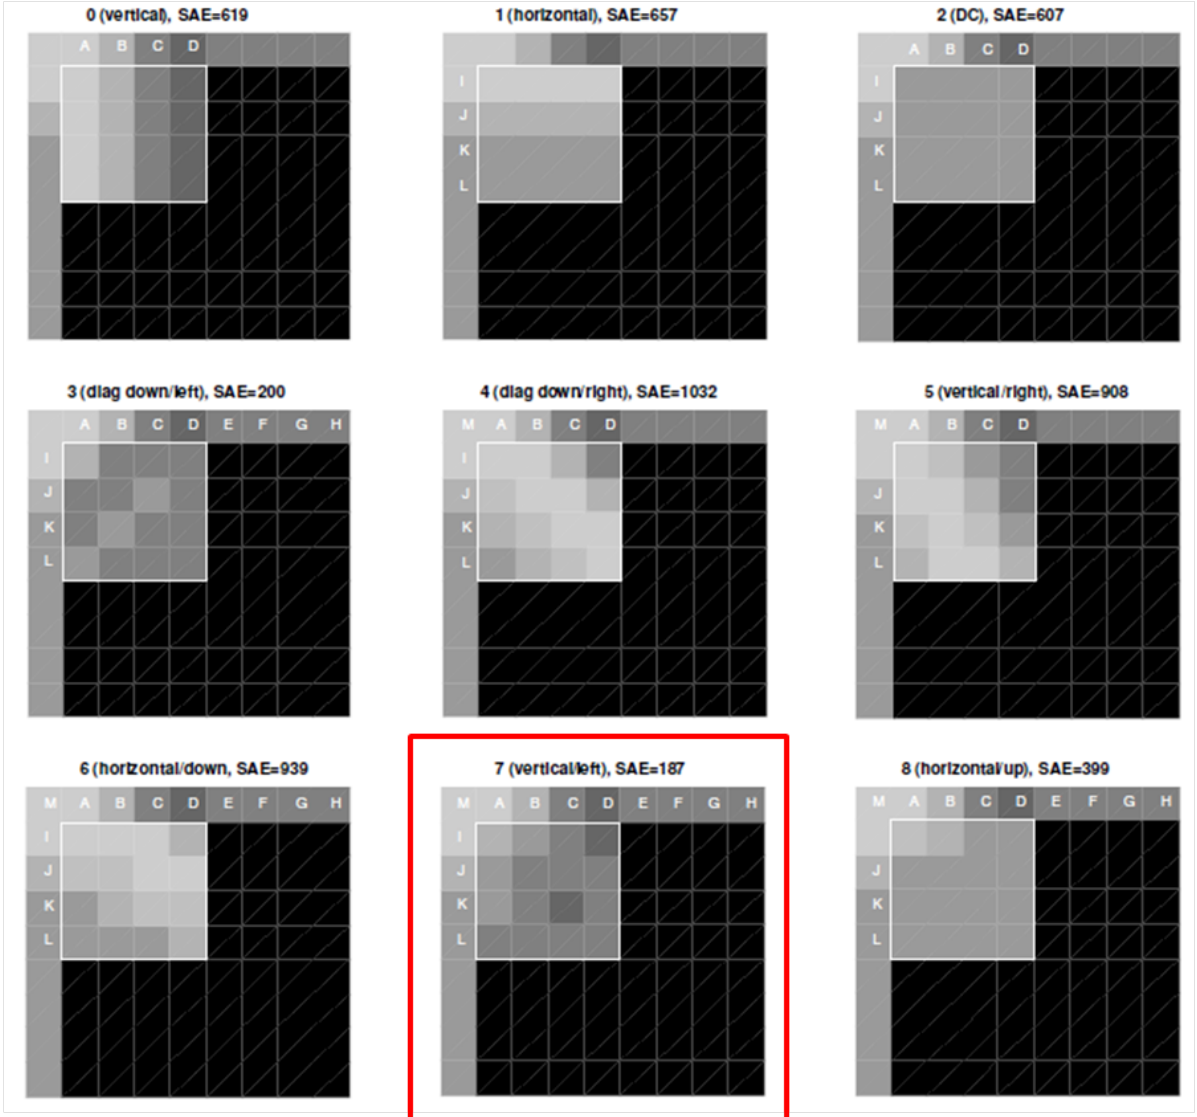

Quelle: Richardson, I. E. G.: H.264 / MPEG-4 Part 10: Intra Prediction. `http://www.vcodex.com/h264.html`. 2003.

Intraprädikation (englisch *Intra Prediction*) III

- Bei $16 \cdot 16$-Blöcken: Vier Richtungen (drei ident zu $4 \cdot 4$)

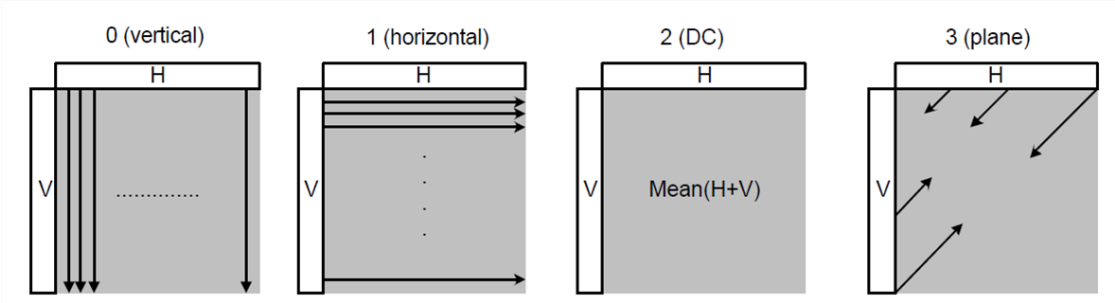

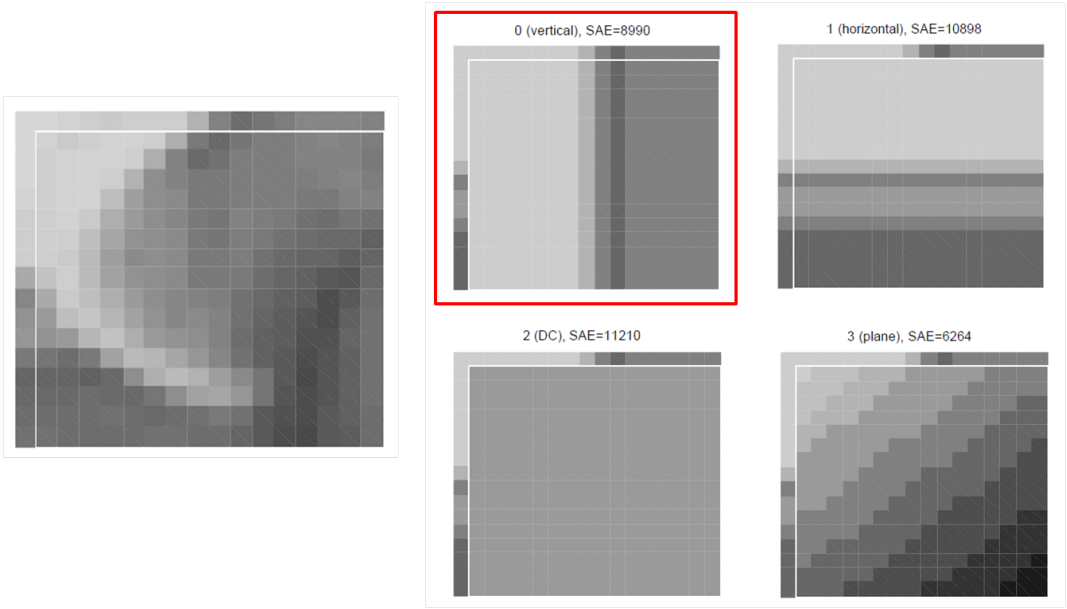

Quelle: Richardson, I. E. G.: H.264 / MPEG-4 Part 10: Intra Prediction. `http://www.vcodex.com/h264.html`. 2003.

Quantisierung

- Quantisierungsmatrix (JPEG-ähnlich) mit Skalierung (AAC-ähnlich)
  - Höhere Frequenzen werden durch Skalierung stärker quantisiert
  - Koeffizientenskalierung automatisch (später einstellbar)
  - Quantisiererschrittweite unabhängig von Skalierung (Parameter Q_{step})
- Quantisierungsparameter QP
  - Bestimmt Quantisiererschrittweite Q_{step} (Divisor)
  - Wertebereich 1 bis 51 (später: 0 bis 51)
  - $QP = 6 \rightarrow Q_{step} = 1{,}25$
  - $QP + 6 \rightarrow 2Q_{step}$ bzw. $QP + 1 \rightarrow \sqrt[6]{2}Q_{step}$
  - $QP - 6 \rightarrow \frac{Q_{step}}{2}$ bzw. $QP - 1 \rightarrow \frac{Q_{step}}{\sqrt[6]{2}}$
  - Pro Makroblock einstellbar

Deblocking-Filter

- Adaptives Tiefpassfilter zur Glättung von Blockkanten
  - Berücksichtigt Makroblockmodi und -kantenpixel
  - Erhält hinreichend harte Kanten (Schärfe)
  - Stärke zusätzlich pro Videosequenz einstellbar (auch deaktivierbar)

→ Zumeist subjektive Qualitätsverbesserung

- Wird nach dem (De-)Kodieren jedes Bildes angewandt

→ P- und B-Prädiktion auf gefilterten Bildern

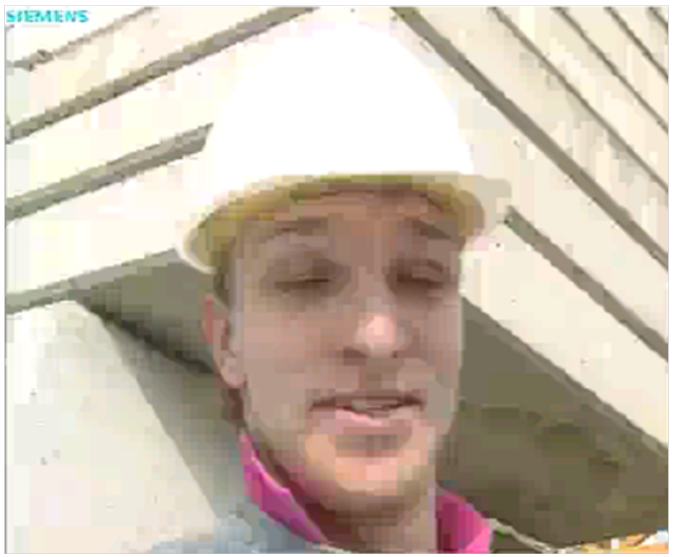

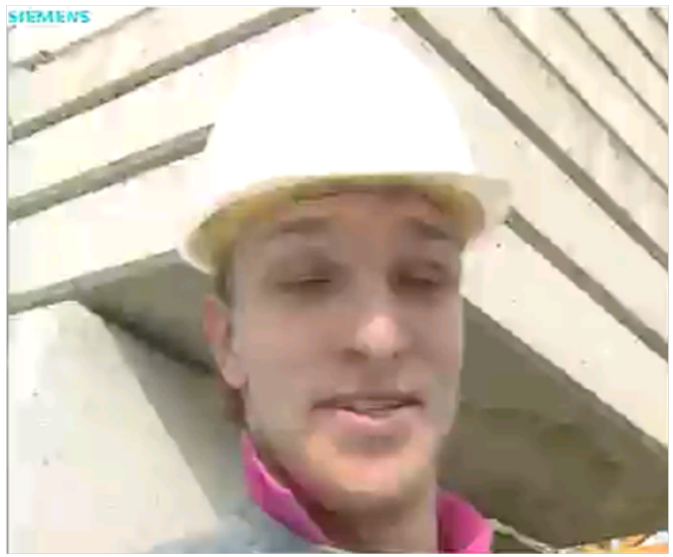

Danke für die Aufmerksamkeit!

Fragen?