

Ergänzungen Multi-Objekt-Tracking und Multi-Sensorfusion

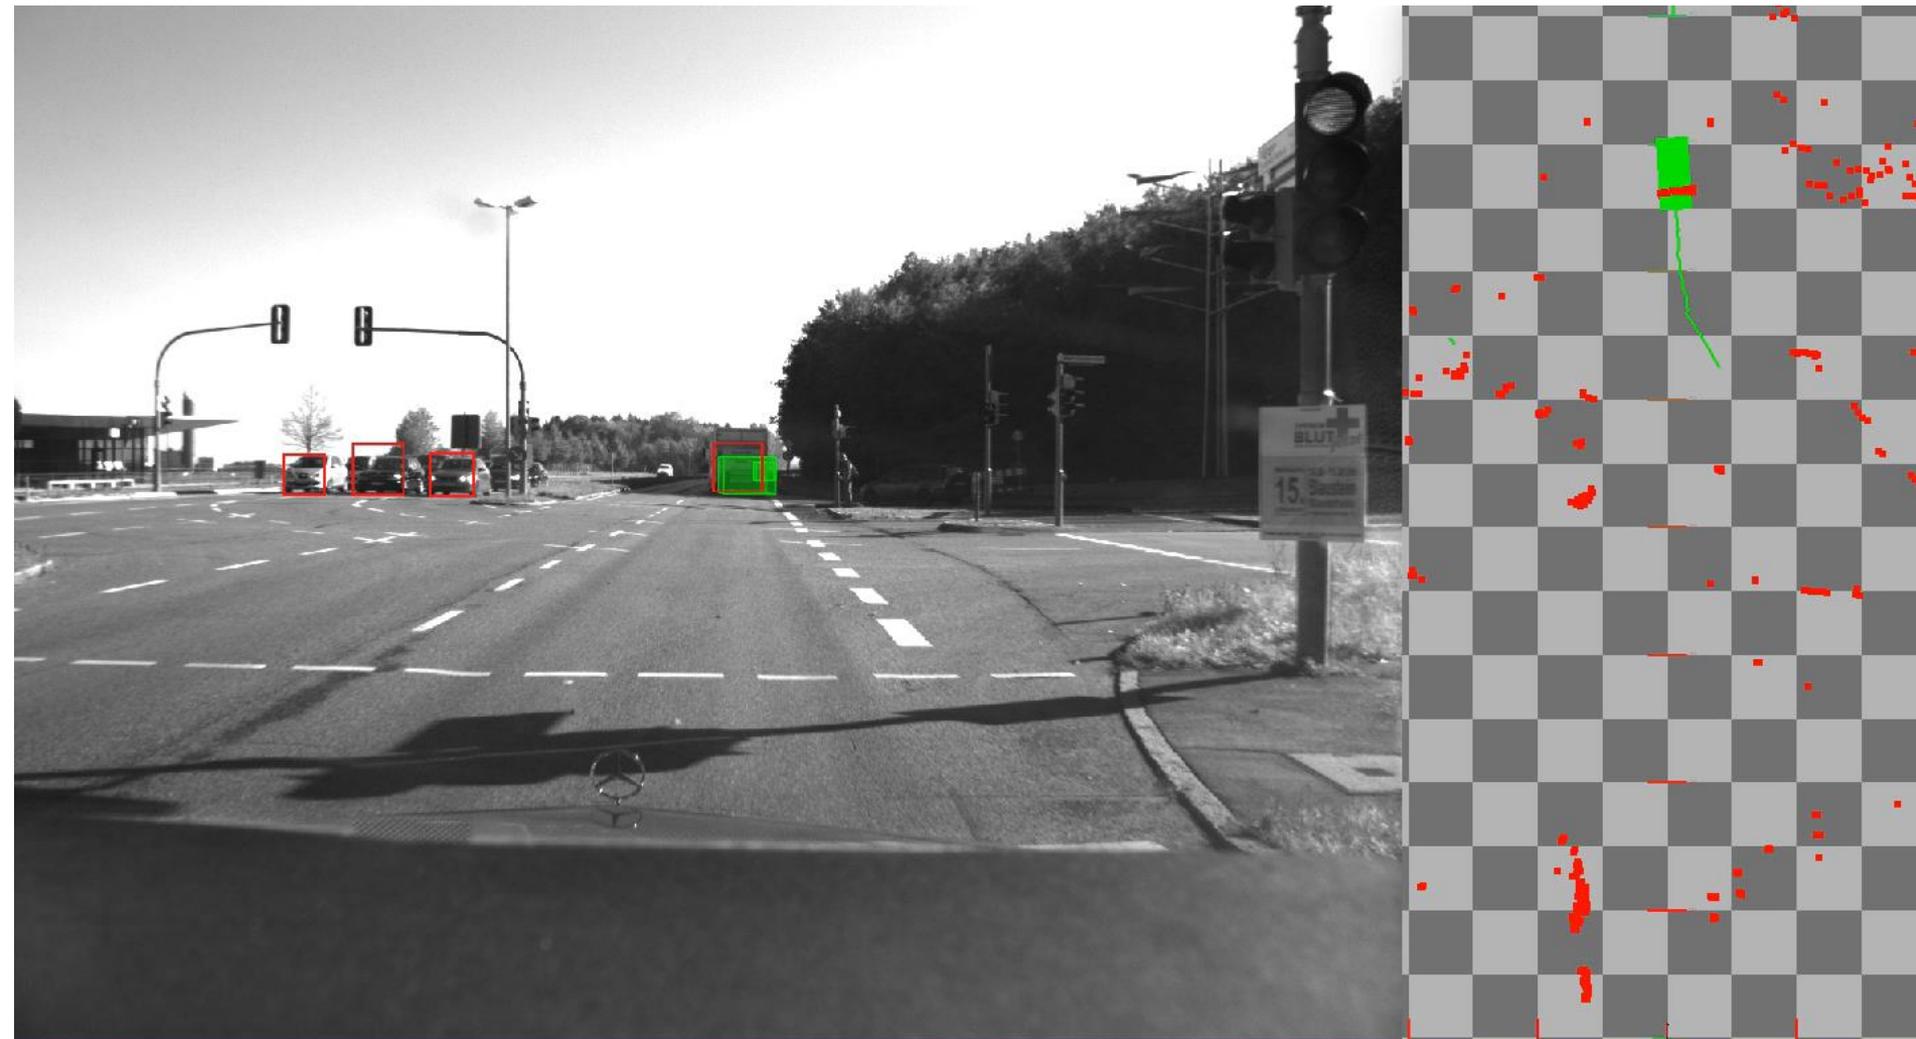
Prof. Klaus Dietmayer

Motivation

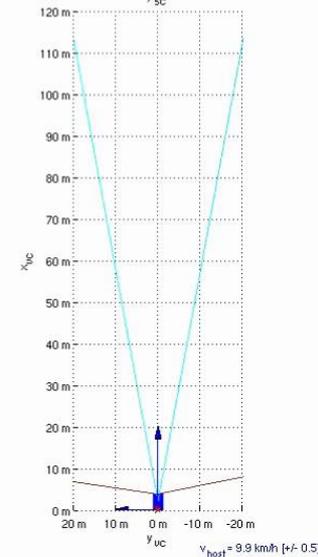
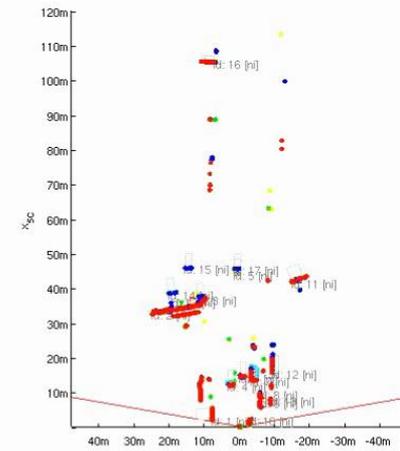
- Multi-Objekt-Tracking ist Voraussetzung für viele Fahrerassistenzsysteme und das automatisierte Fahren
 - Komplexität steigt mit Automatisierungsgrad
- ⇒ Anforderungen an Tracking-Algorithmus
- Geringe Komplexität
 - Integrierte Existenzschätzung
 - Hohe Objektdichte



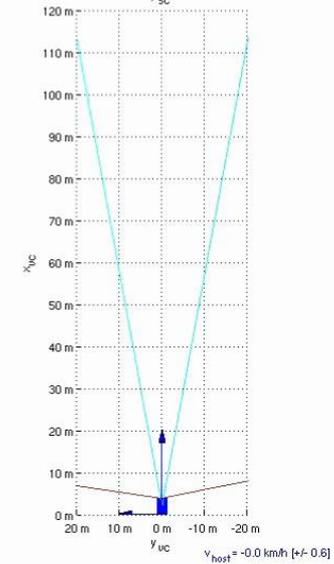
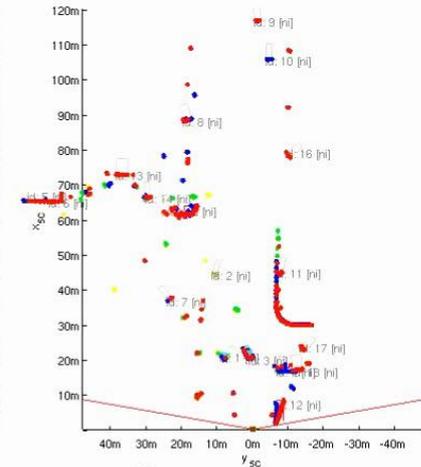
Multi-Sensor, Multi-Objekt Tracking mit Lidar und Video



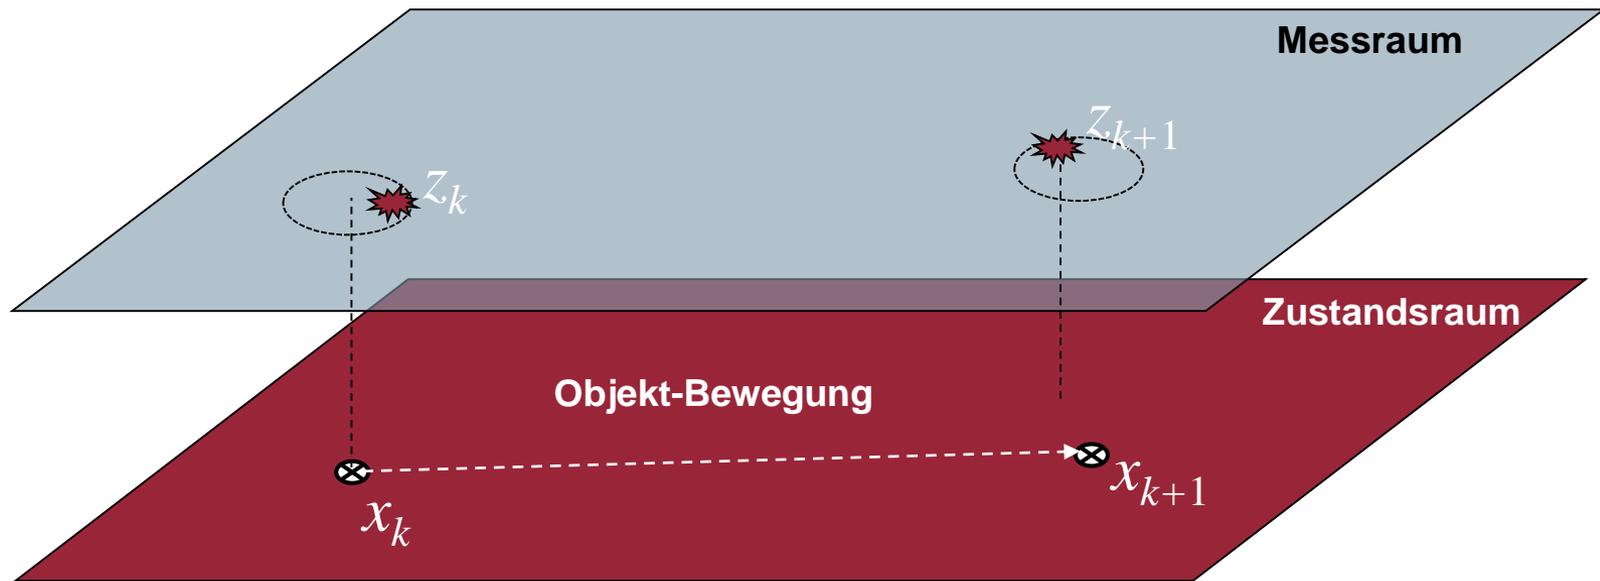
Beispielvideo: Sensorfusion von Video- und Laserscanner im Innenstadtbereich



Beispielvideo: Sensorfusion von Video- und Laserscanner im Innenstadtbereich, Kreuzung

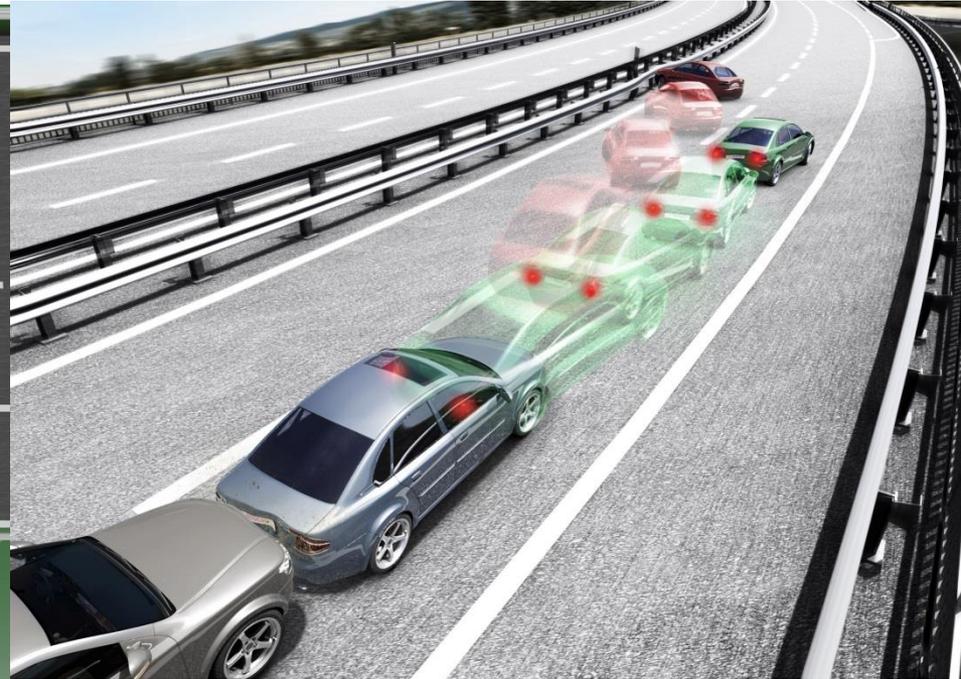
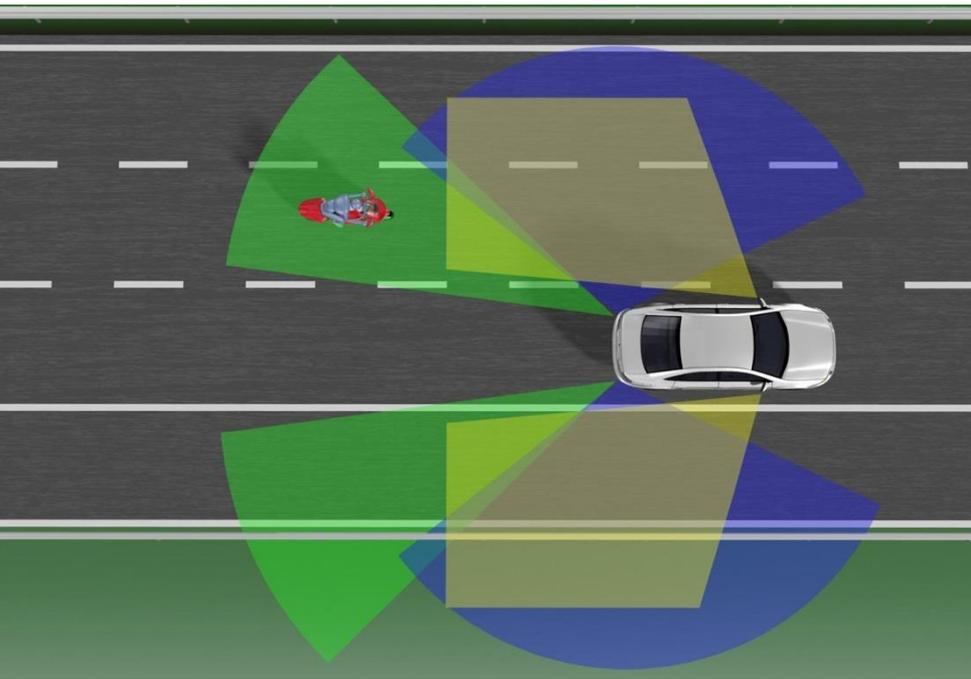


Bayes-Filter



$$\longrightarrow p_k(x_k | z_{1:k}) \xrightarrow{\text{Prädiktion}} p_{k+1|k}(x_{k+1} | z_{1:k}) \xrightarrow{\text{Update}} p_{k+1}(x_{k+1} | z_{1:k+1}) \longrightarrow$$

- Implementierung
 - Kalman-Filter
 - Sequenzielle Monte-Carlo Methoden (Partikel-Filter)



Multi-Objekt Tracking

Prof. Klaus Dietmayer

Herausforderungen des Multi-Objekt-Trackings

Schätzen von

- Objektanzahl
- Objektzustand

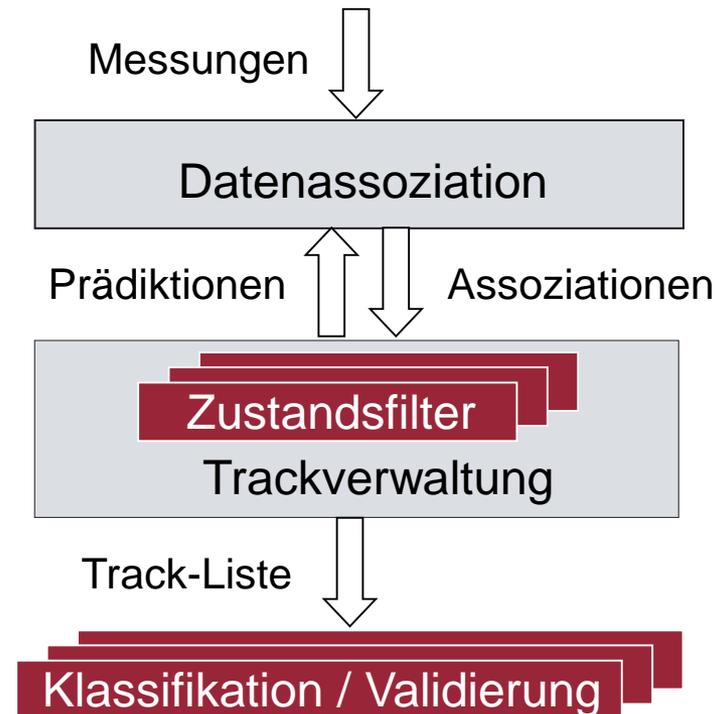
unter Berücksichtigung von

- Erscheinen und Verschwinden von Objekten
- Fehldetektionen
- Falschalarmen
- ...

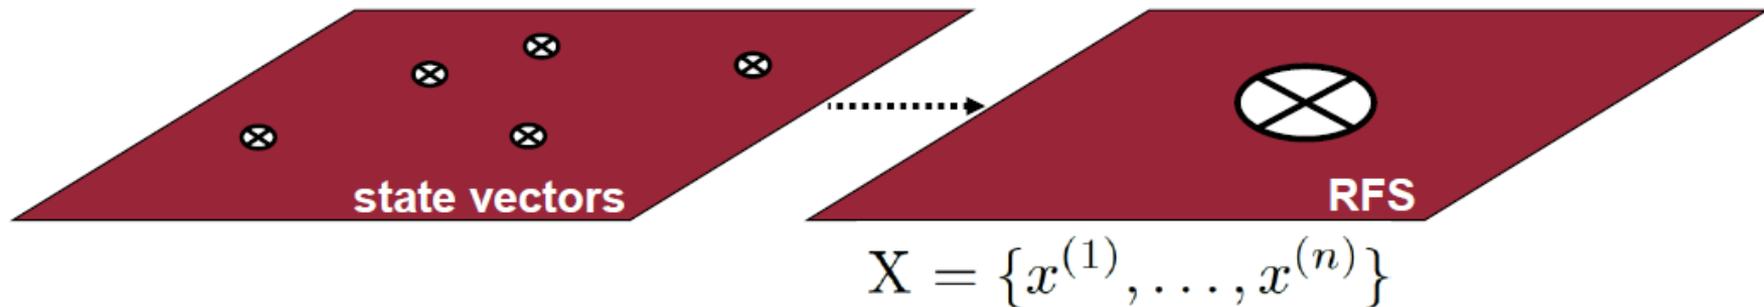
Klassischer Ansatz: Multi-Instanzen-Kalman-Filter

- Multi-Objekt-Tracking häufig durch mehrere Kalman-Filter realisiert
- Heuristiken zwischen Einzelschritten führen zu Informationsverlust

⇒ Nutzung der Random Finite Set Theorie



Random Finite Sets (RFS)

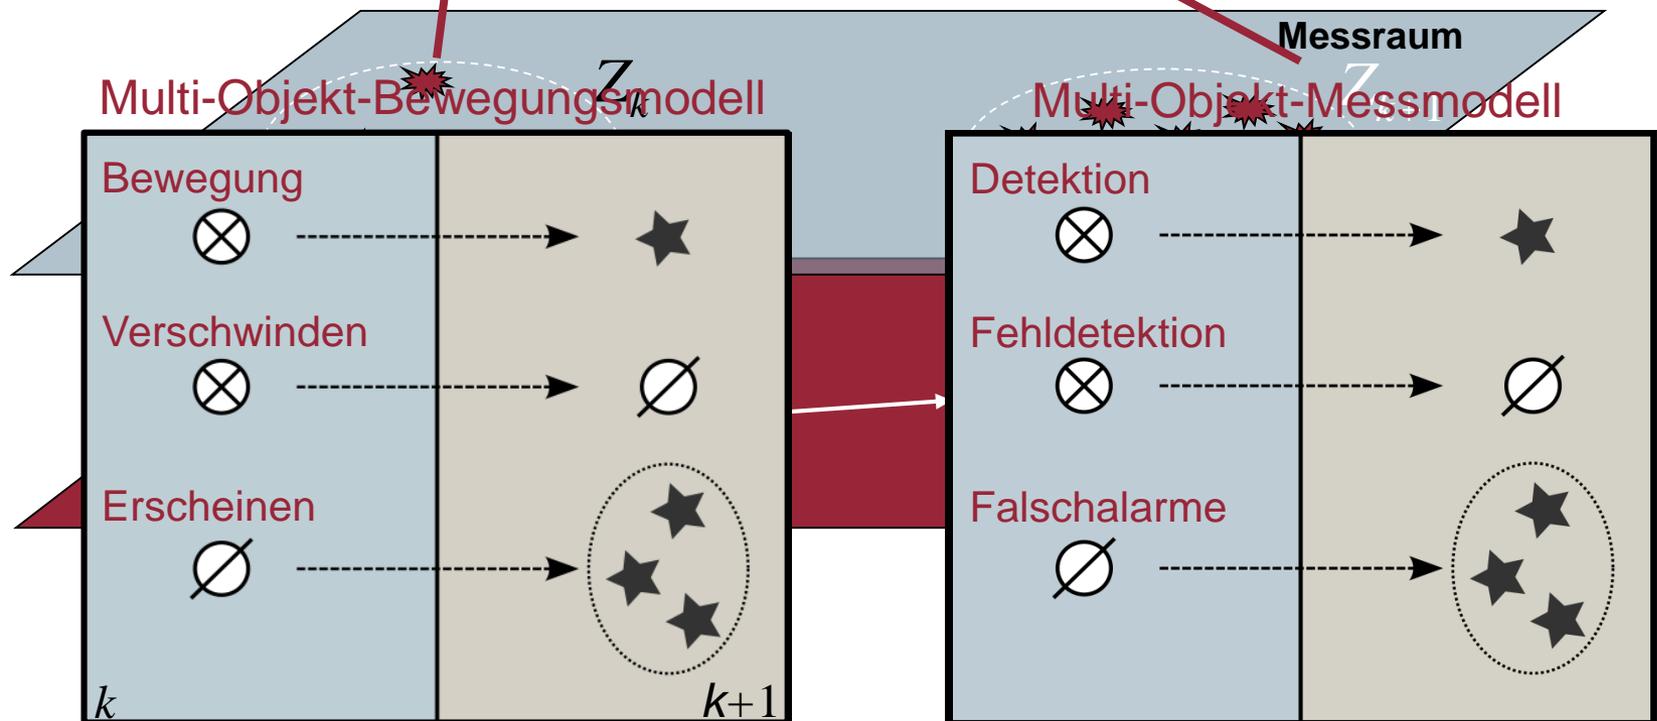


- Definiert eine (endliche) Menge von Zustandsvektoren
- Die Anzahl der Zustandsvektoren in der Menge ist ebenfalls unbekannt und eine Zufallsvariable, die geschätzt wird (Kardinalität)
- Menge repräsentiert also einen Multi-Objekt Zustand geschlossen
- Die Modellierung von Abhängigkeiten zwischen den Objekten ist möglich

Multi-Objekt-Bayes-Filter unter Nutzung von RFS

- Generalisierung des Bayes-Filters

$$\rightarrow \pi_k(X_k | Z_{1:k}) \xrightarrow{\text{Prädiktion}} \pi_{k+1|k}(X_{k+1} | Z_{1:k}) \xrightarrow{\text{Update}} \pi_{k+1}(X_{k+1} | Z_{1:k+1}) \rightarrow$$

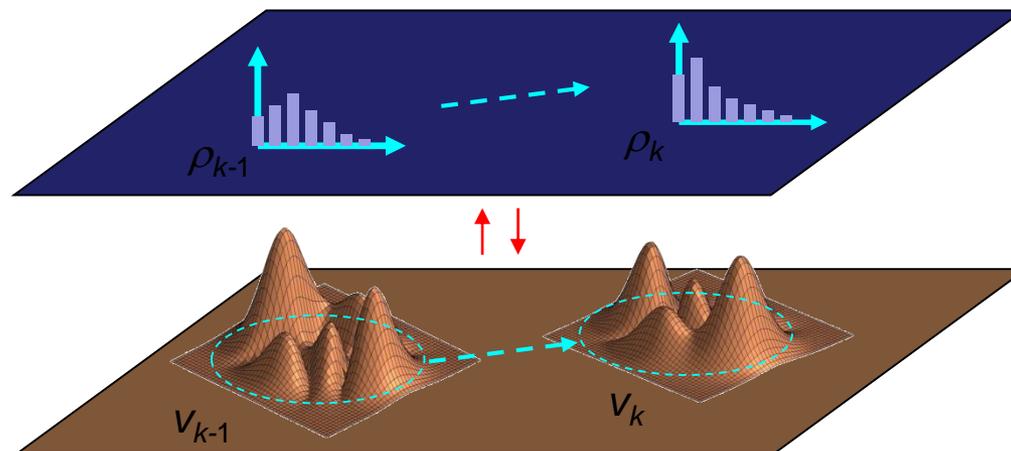


Multi-Objekt-Bayes-Filter Implementierung

Filter-Verfahren	Komplexität	Kardinalitäts-schätzung	Existenz-wahrscheinlichkeit	Objekt-Extraktion	Objekt-Interaktion	
Sequenzielle Monte-Carlo Methoden (Vo 2005)	—	⊕	○	○	⊕	Moment-Approximation
Probability Hypothesis Density (PHD) Filter (Mahler 2003)	⊕	—	—	—	—	
Cardinalized PHD Filter (Mahler 2007)	⊕	⊕	—	—	—	
Cardinality Balanced Multi-Bernoulli Filter (Vo 2009)	⊕	—	⊕	○	—	Parameter-Approximation
δ -Generalized Labeled Multi-Bernoulli Filter (Vo 2011)	—	⊕	⊕	⊕	⊕	
Labeled Multi-Bernoulli Filter (Reuter 2014)	⊕	⊕	⊕	⊕	⊕	

Multiobjekt Bayes Filter: Moment-Approximationen

- PHD-Filter (Mahler2003): Approximation durch erstes Moment
- CPHD-Filter (Mahler2007): erstes Moment + Kardinalitätsverteilung



Kardinalitäts-
Verteilung

Wahrscheinlichkeits-
verteilung Objektanzahl

PHD oder
Intensitätsfunktion

1. Moment der
Multiobjekt-Verteilung

Parameter-Approximation: Labeled Random Finite Sets

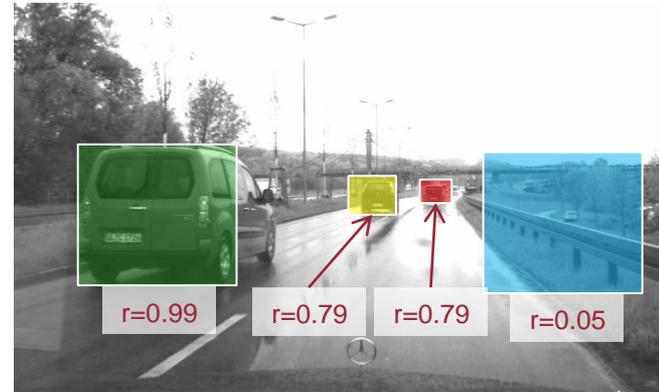
Labeled Multi-Bernoulli (LMB) Random Finite Set

$$\pi = \left\{ \left(r^{(\ell)}, p^{(\ell)} \right) \right\}_{\ell \in \mathbb{L}}$$

Existenz-
wahrscheinlichkeit

Räumliche
Verteilung

Track-IDs



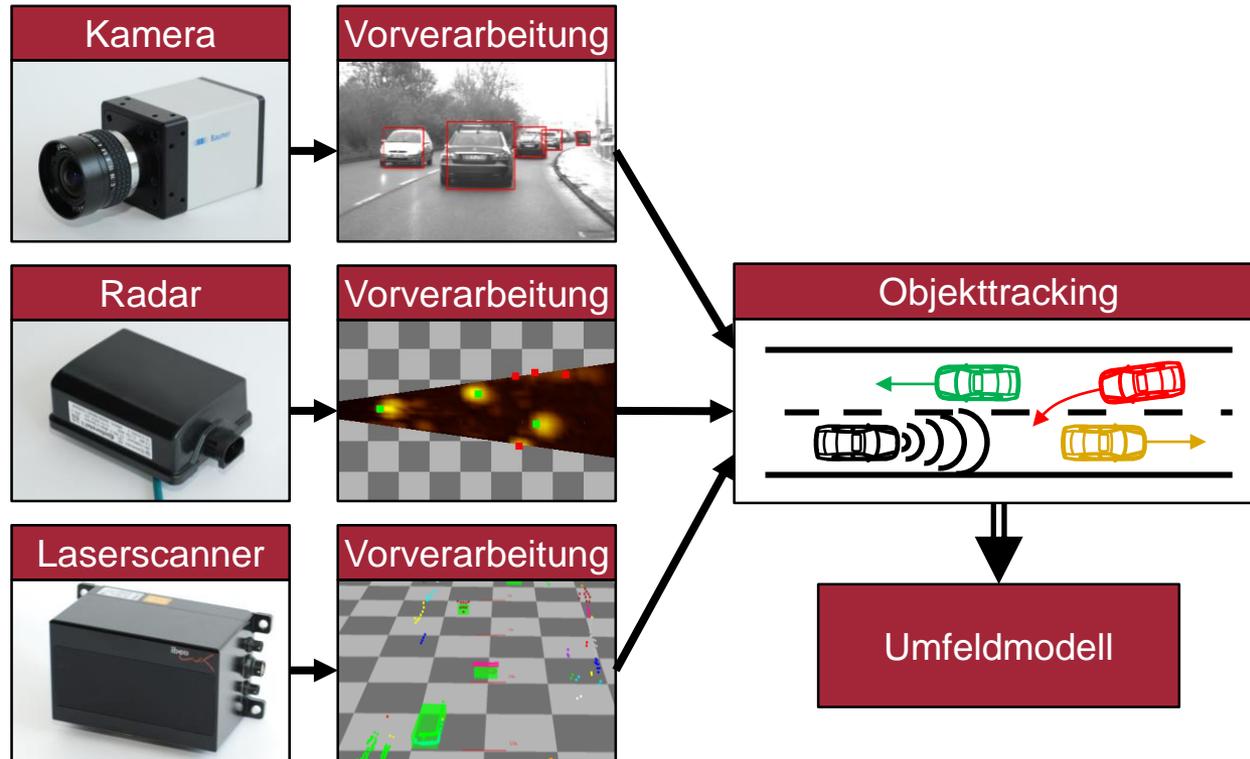
Transformation

Approximation

δ -Generalized Labeled Multi-Bernoulli (δ -GLMB) Random Finite Set



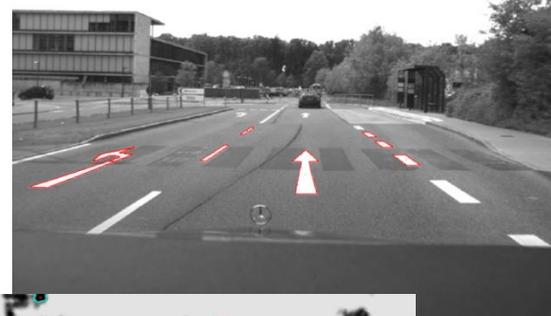
Generische Sensordatenfusion



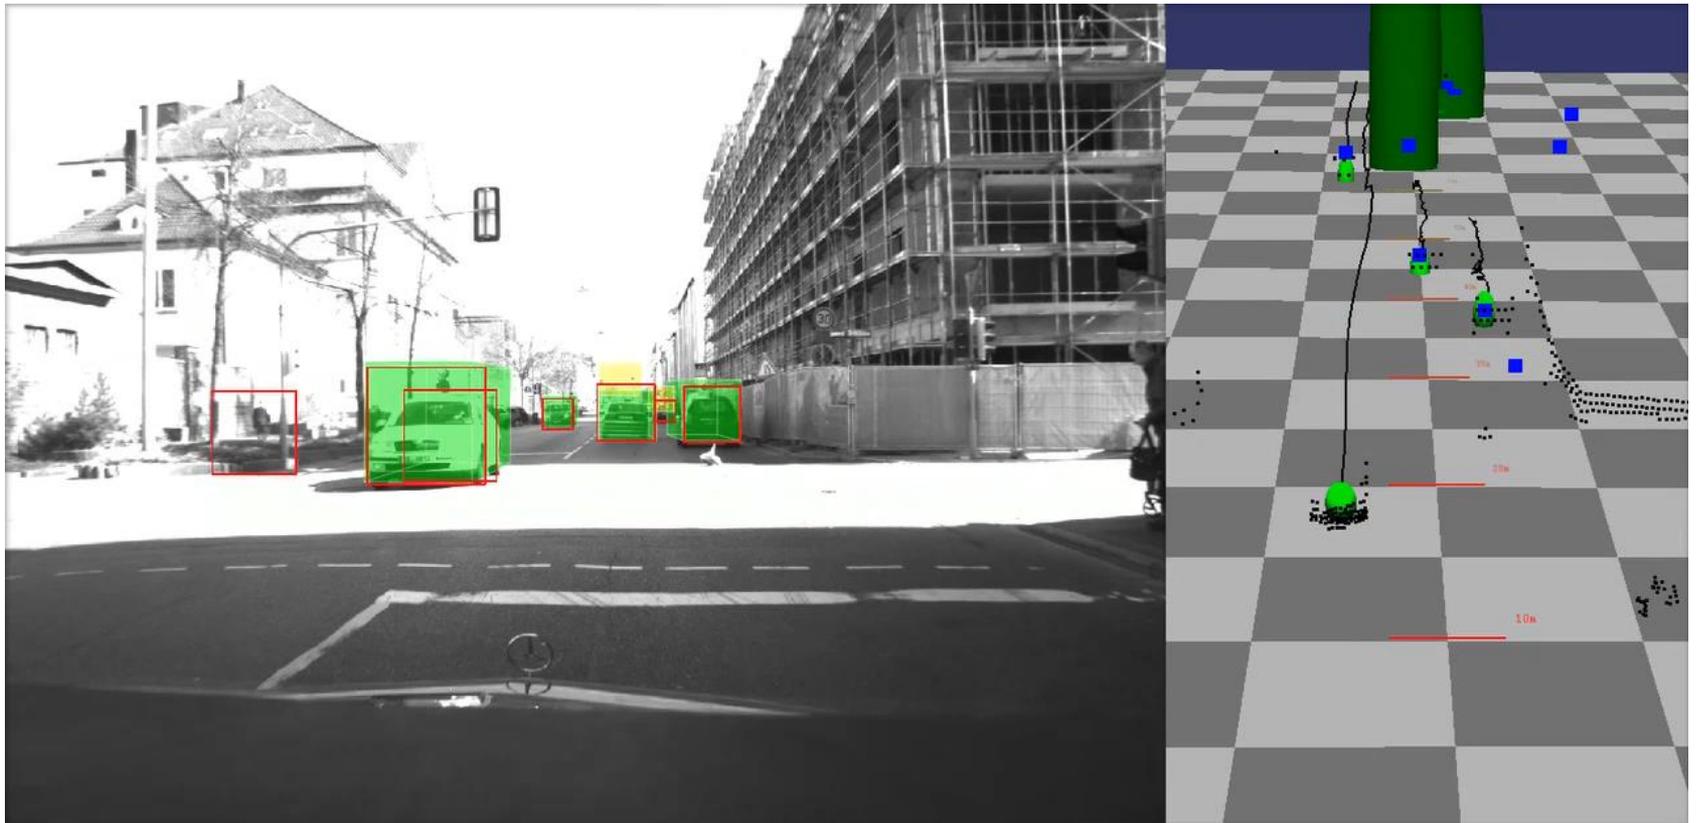
- Austausch von Sensoren im Fusionssystem möglich

Multi-Sensor Lokalisierung

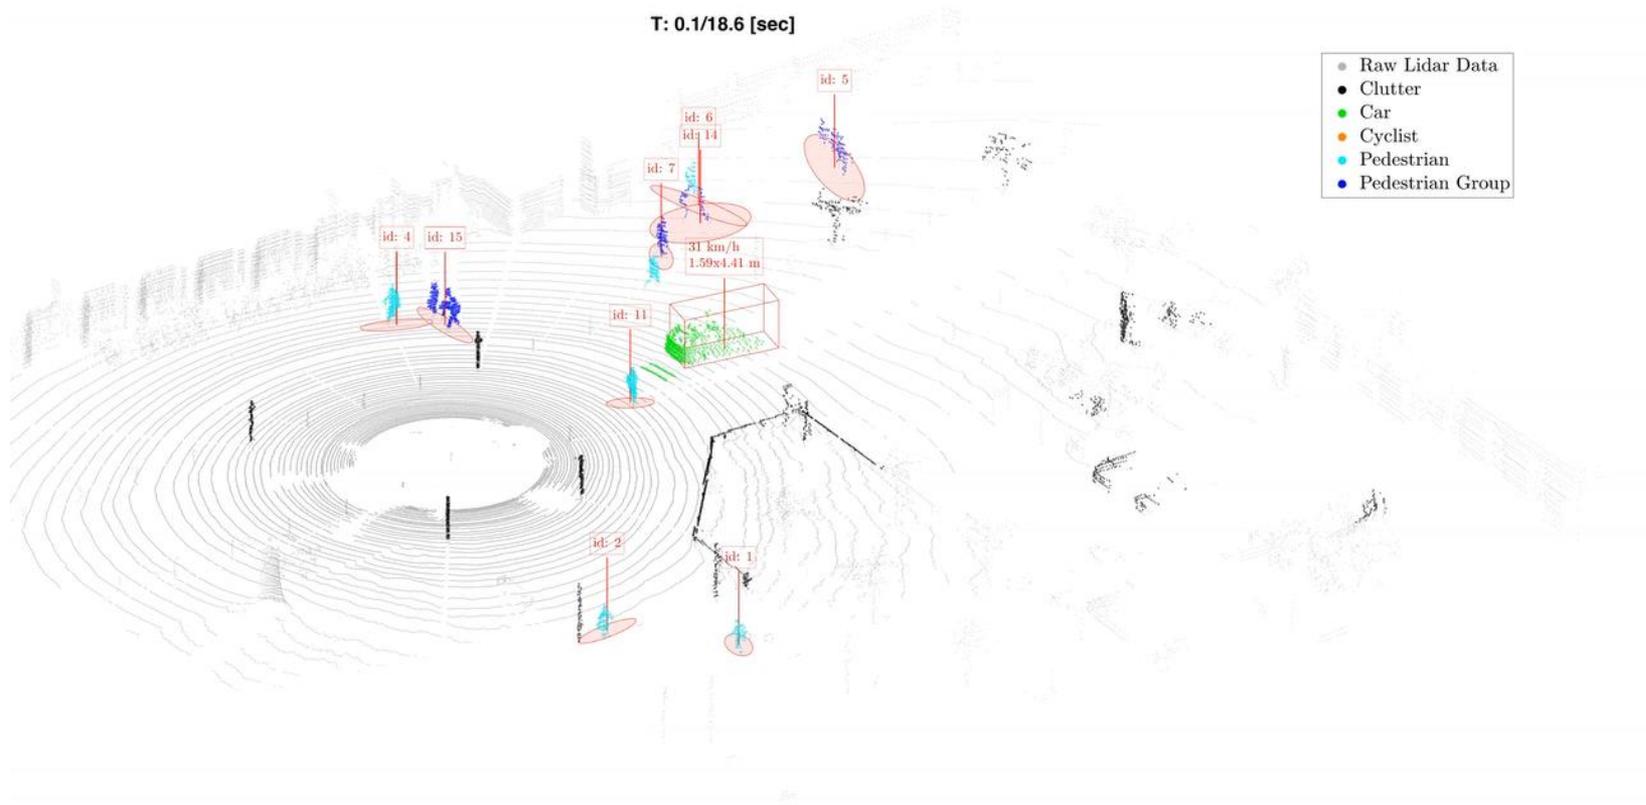
- Digitale Karte (Referenzlinien, Landmarken,...), mit D-GPS System erzeugt
- Feature-basierte Monte-Carlo Lokalisierung
 - Initialisierung:
 - Standard-GPS + Kompass
 - Features
 - Kamera
 - Laser
- Simultaneous Localization and Mapping (SLAM)



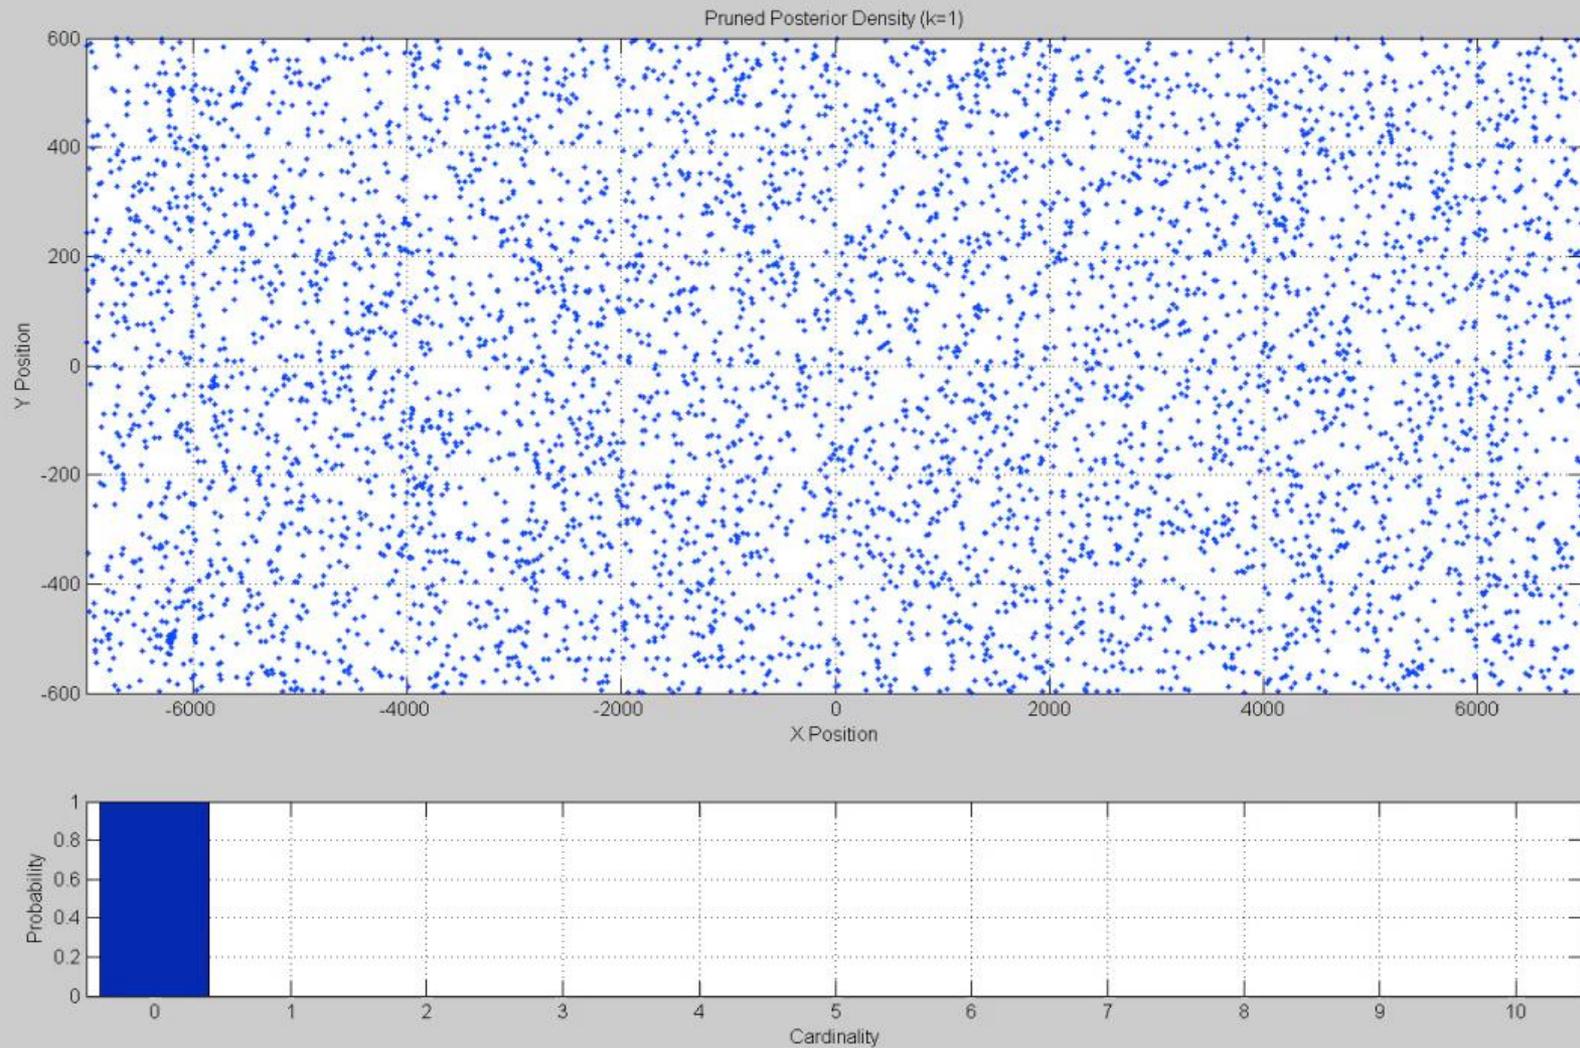
Video Stadtverkehr



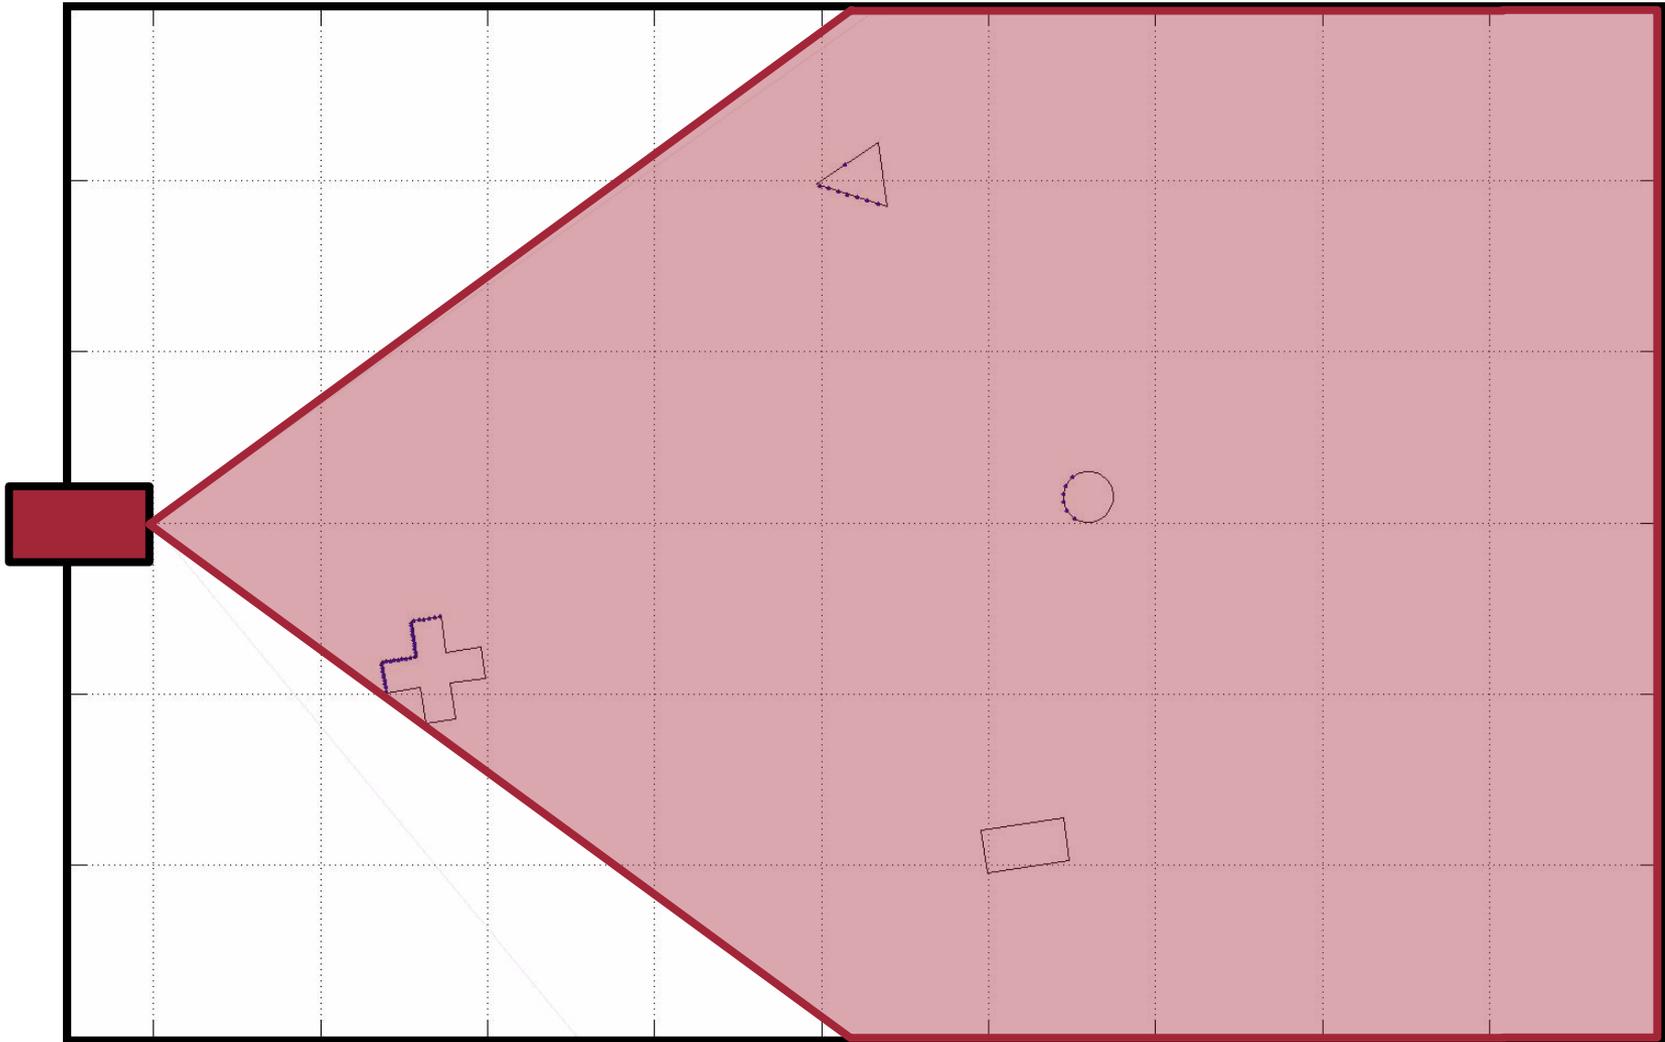
Multi-Objekt-Tracking unter Verwendung von Sensor-Rohdaten



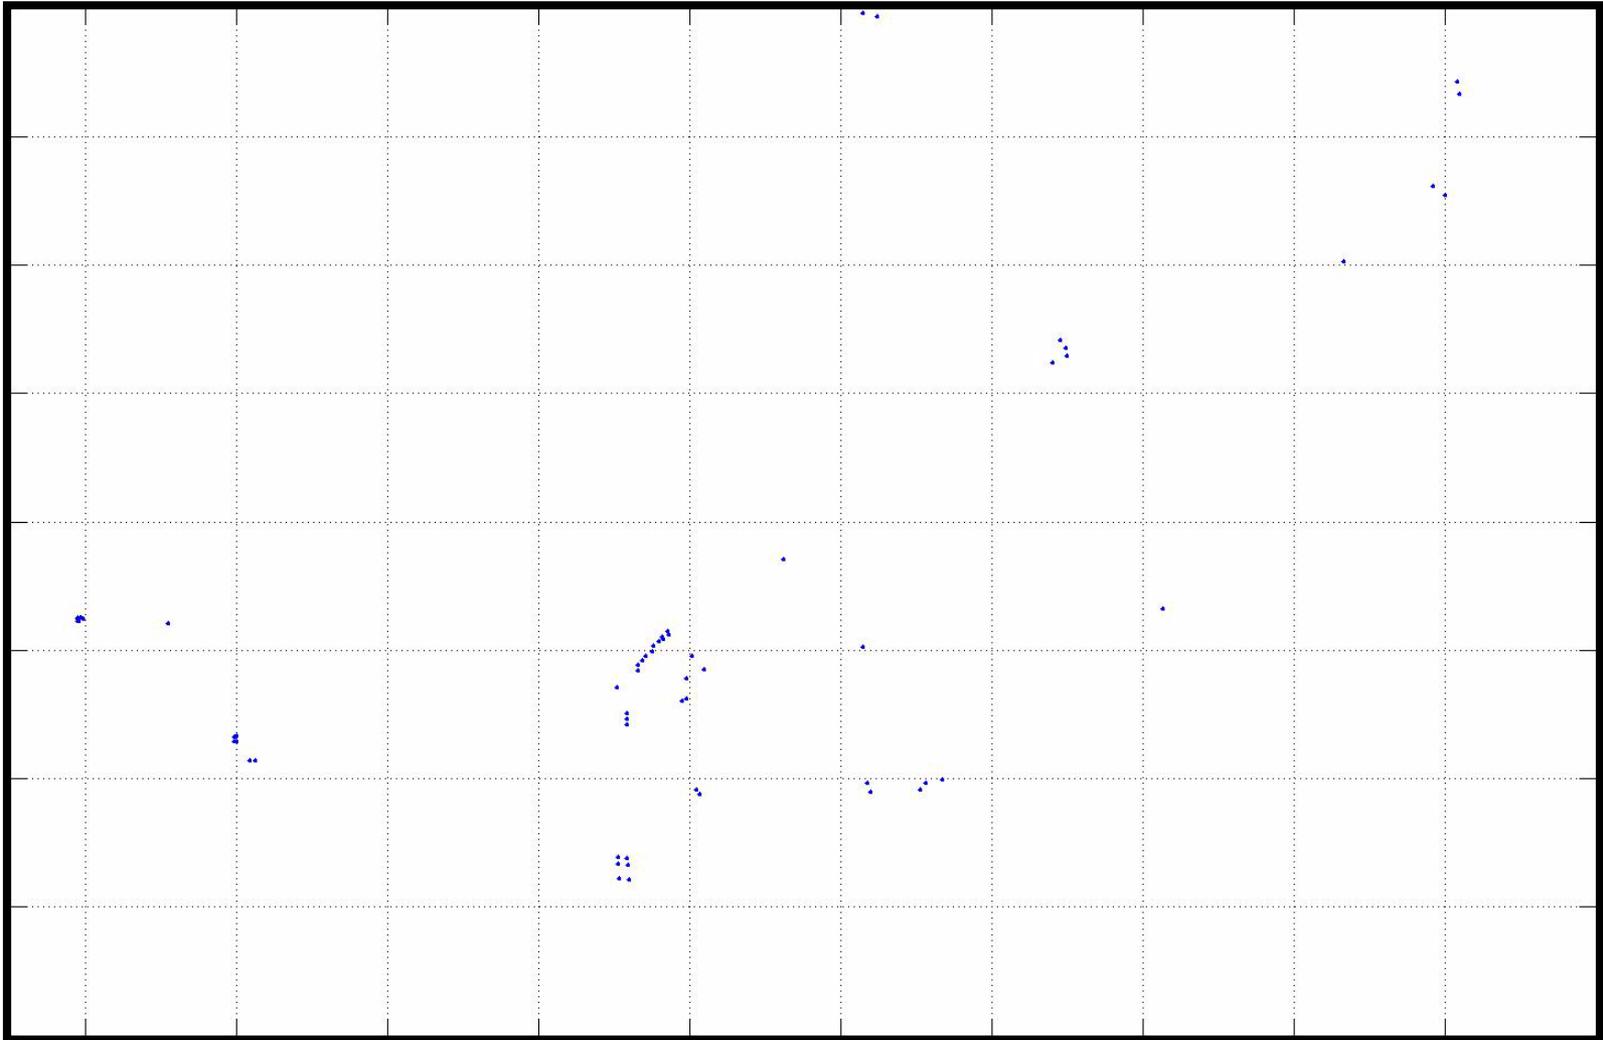
GGIW-LMB Filter – Hohe Falschalarmrate



Ausdehnungsmodellierung mit Gauß-Prozessen

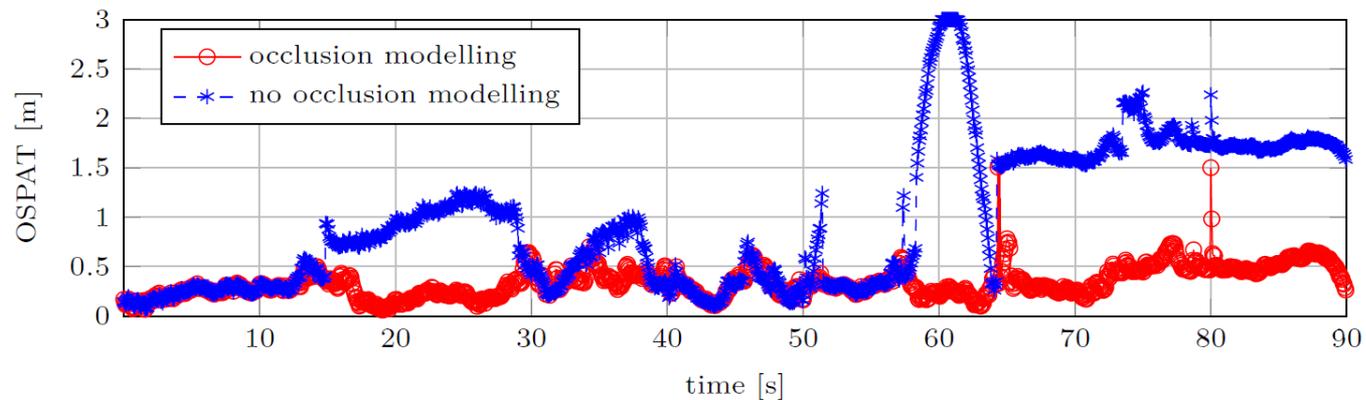
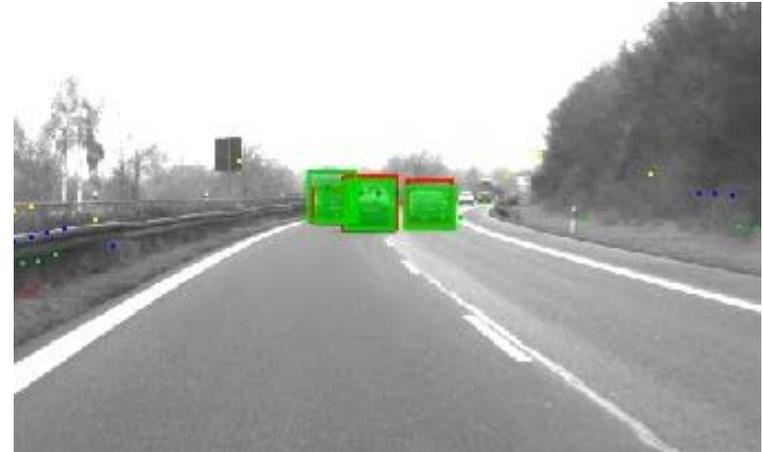


Ausdehnungsmodellierung mit Gauß-Prozessen

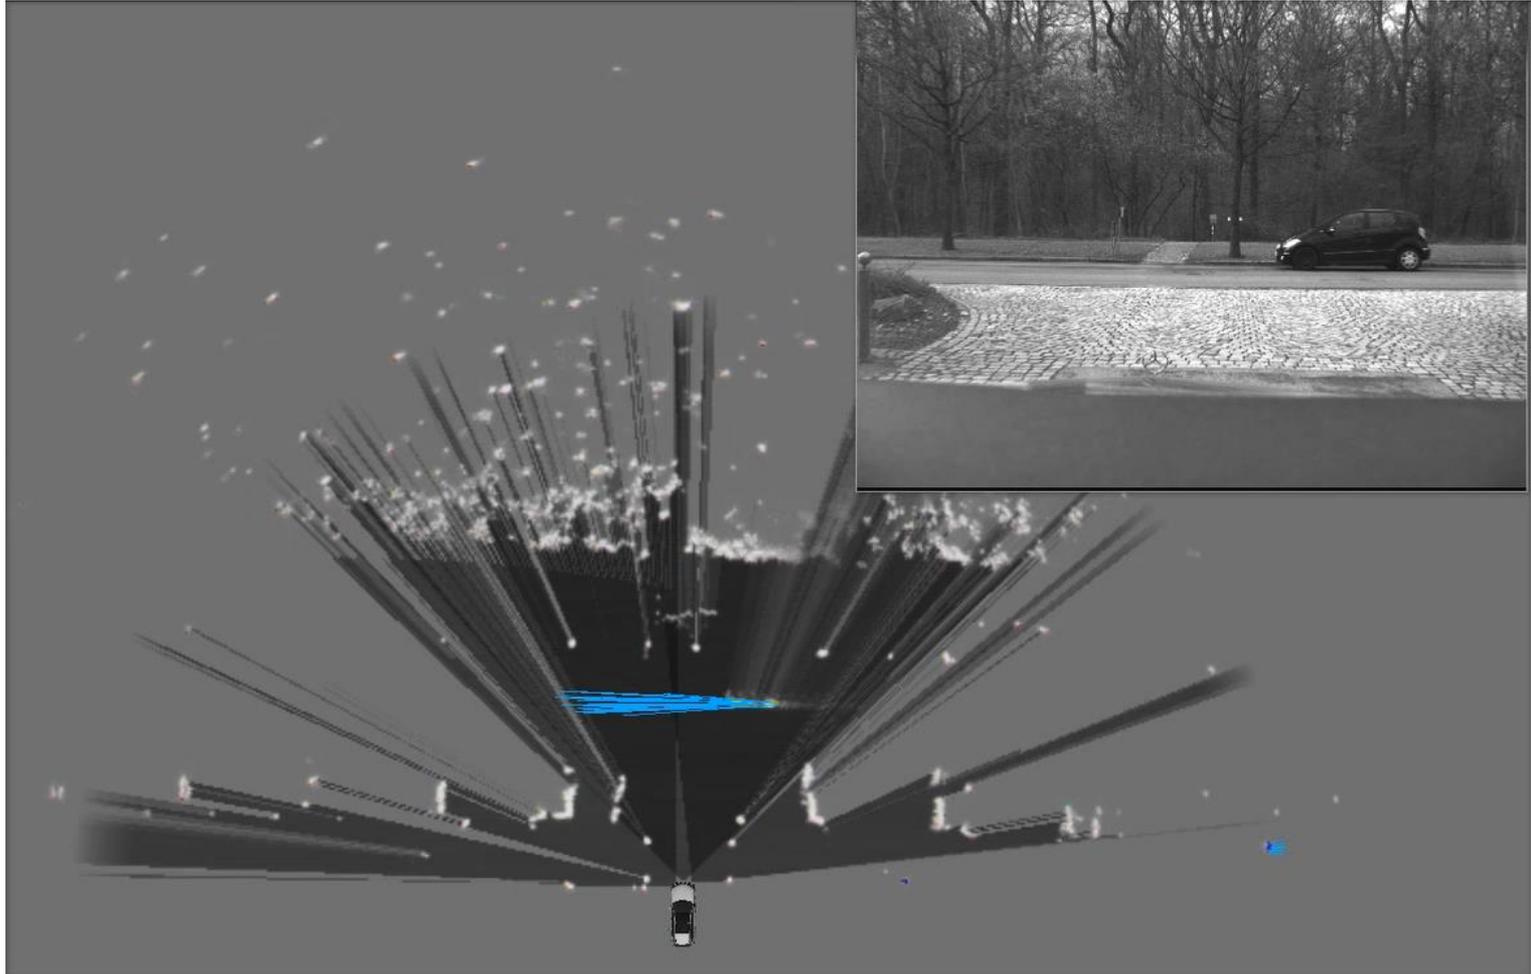


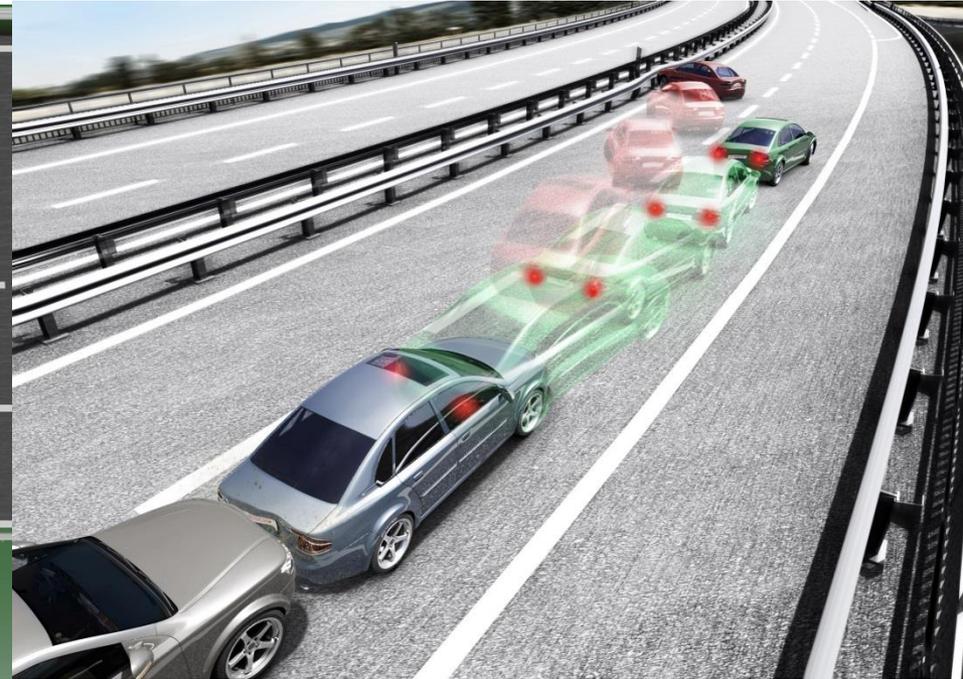
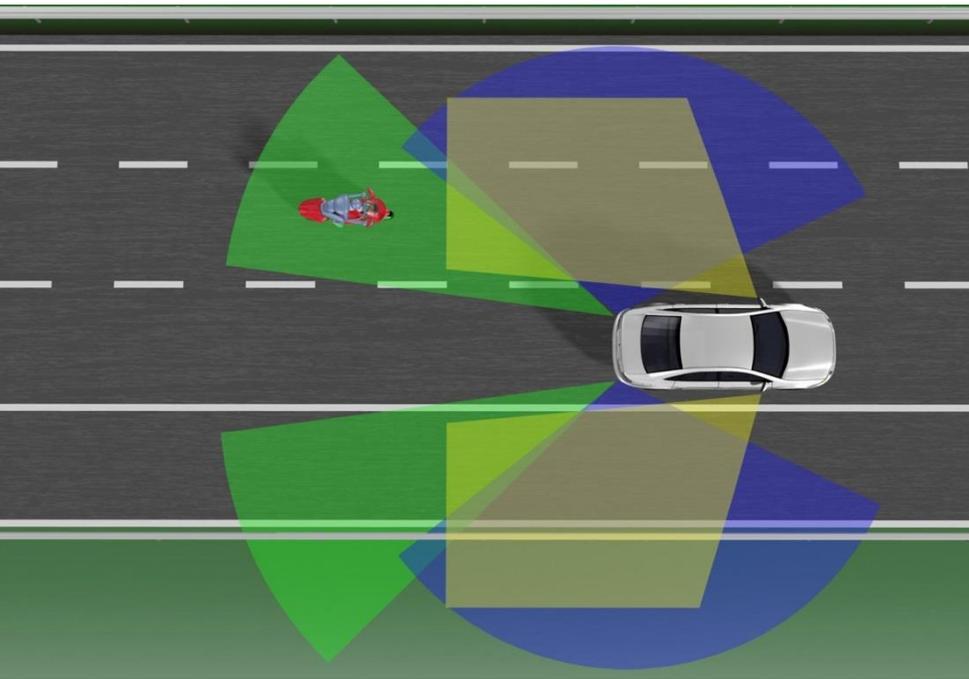
Zustandsabhängige Detektionswahrscheinlichkeit

- Videobild: Verdeckungen aufgrund anderer Verkehrsteilnehmer
- Radar: Detektionen abhängig von Schwellwert für Objektextraktion



Dynamic Grid Map – Video

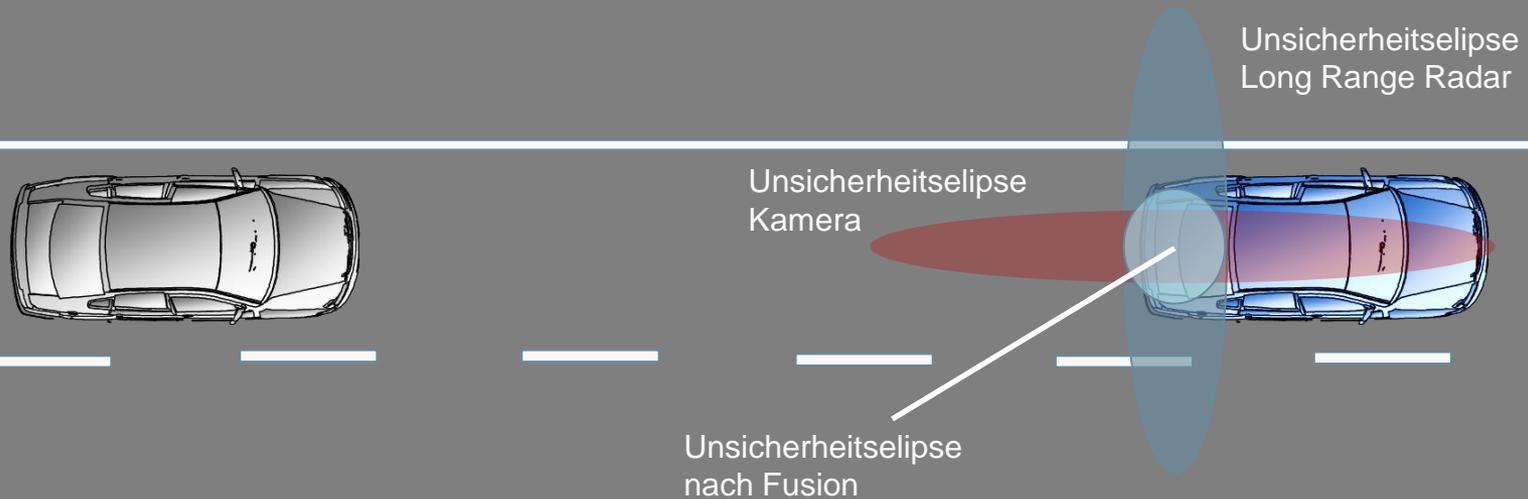




Grundlagen der Sensorfusion

Prof. Klaus Dietmayer

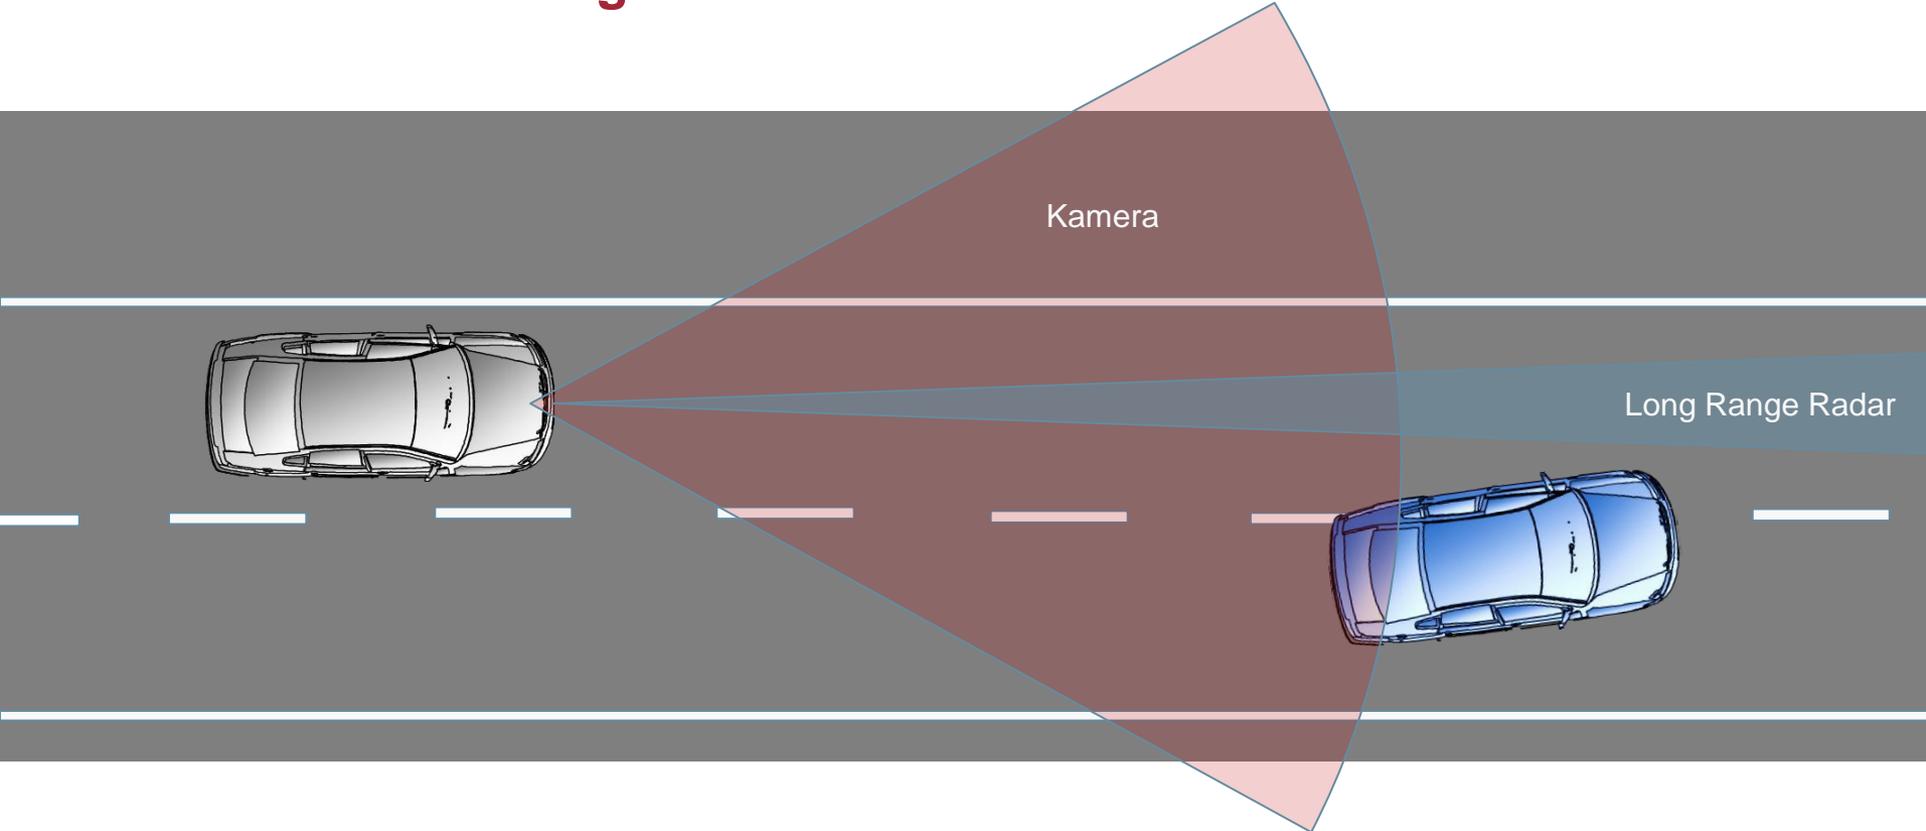
Sensorfusion verringert die Messunsicherheit bei geeigneter Kombination von Sensorprinzipien



Messeigenschaften der Einzelsensoren

- **Radar:** Sehr gute Entfernungsmessung, schlechte Winkelauflösung
- **Kamera:** Sehr hohe horizontale (Winkel-) Auflösung, schlechte Entfernungsschätzung

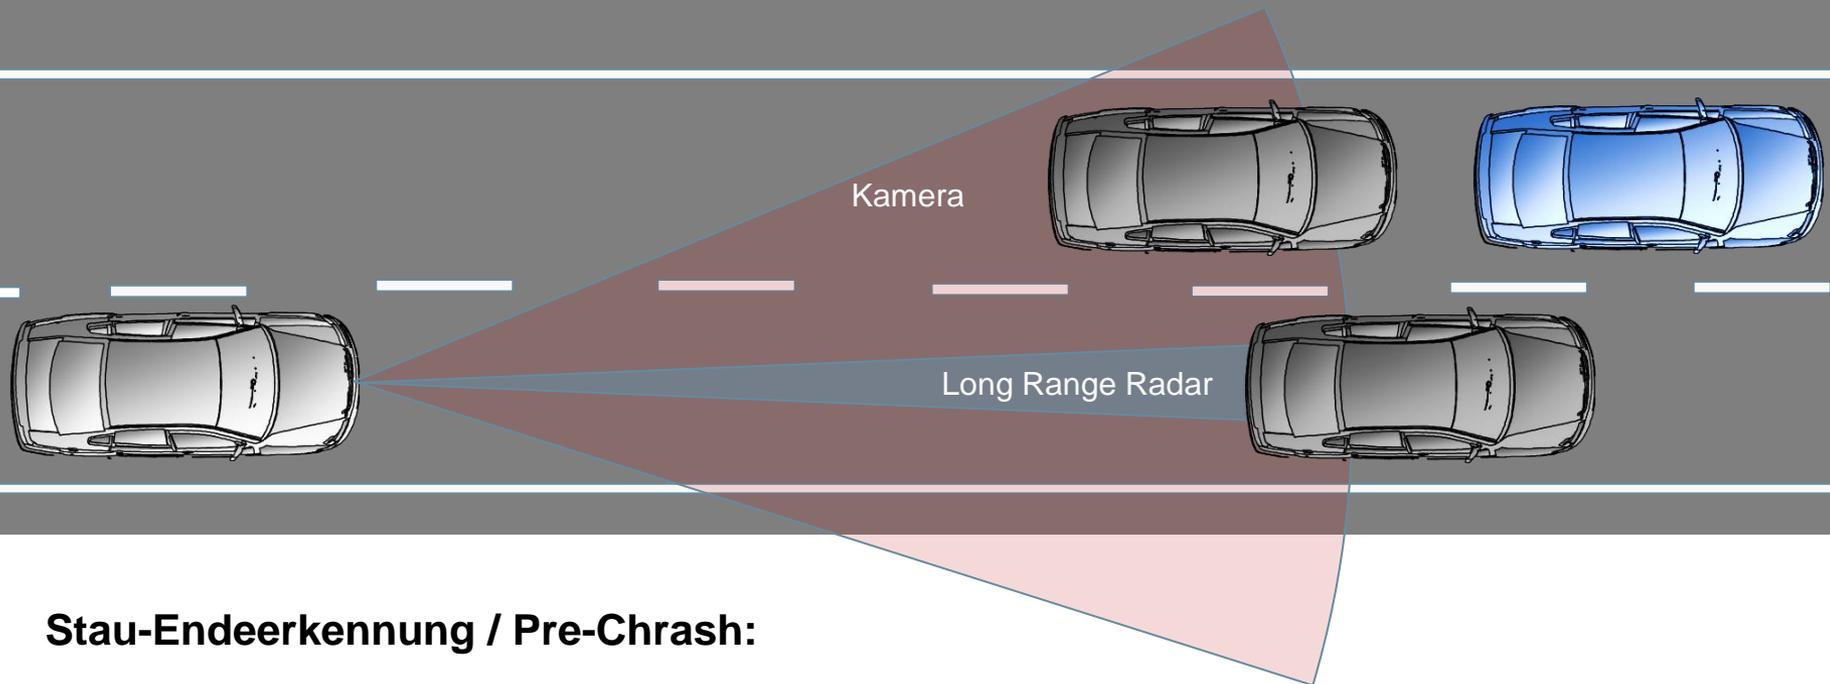
Benefits für ausgewählte ADAS-Funktionen



ACC Komfortverbesserung: Frühzeitiges Erkennen von Cut-In Situationen

- **Kamera:** Sehr hohe horizontale (Winkel-) Auflösung, schlechte Entfernungsschätzung
- **Kamera:** Spurerkennung und spurgenaue Objektzuordnung
- **Radar:** Sehr gute Entfernungs- und Geschwindigkeitsmessung, schlechte Winkelauflösung

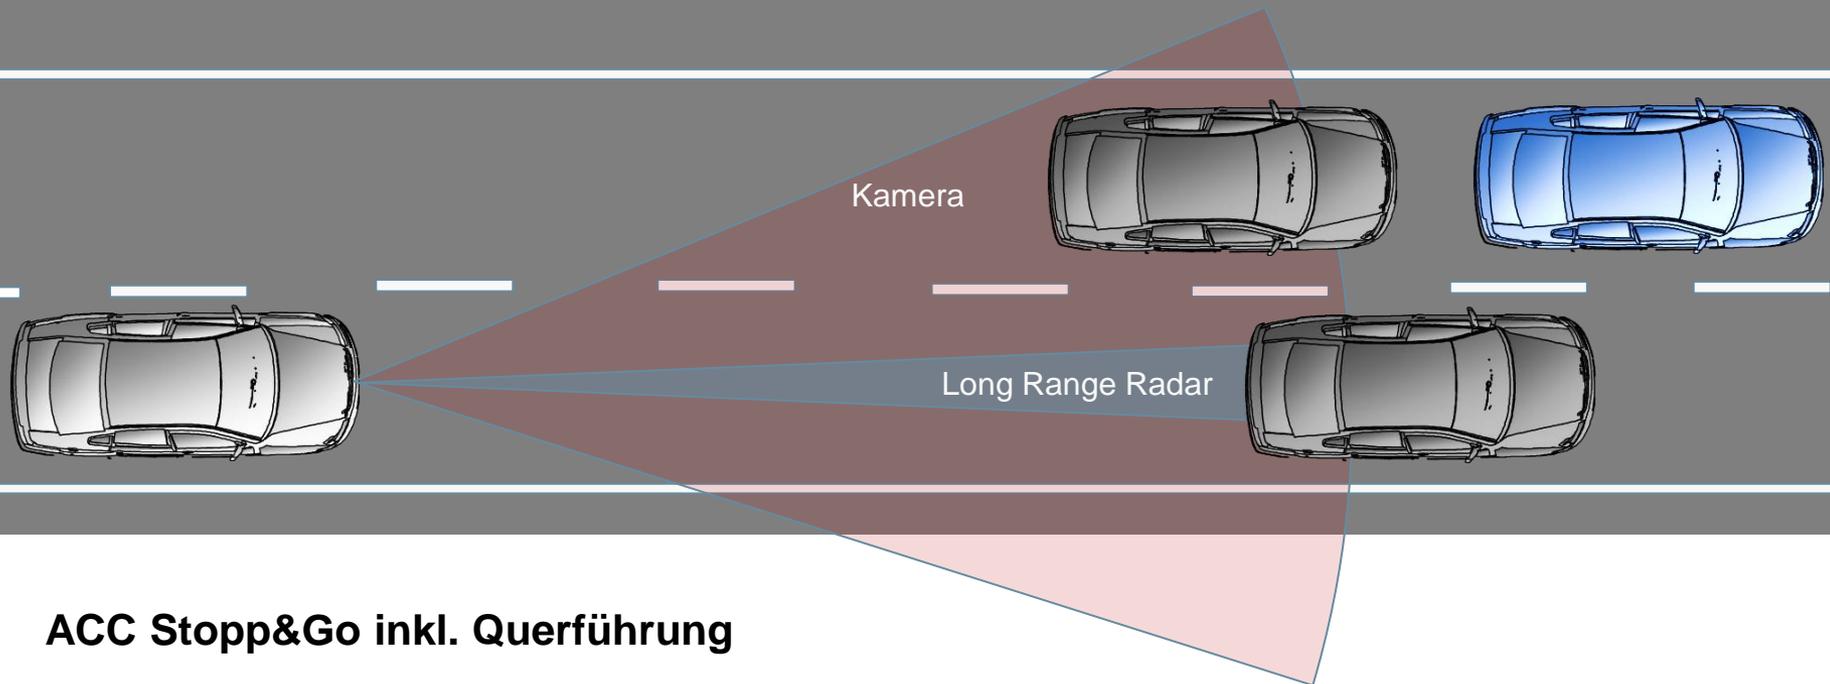
Benefits für ausgewählte ADAS-Funktionen



Stau-Endeerkennung / Pre-Chrash:

- **Kamera:** Klassifikation der Objekte als stehende Fahrzeuge (oder Hindernisse)
- **Radar:** Exakte Bestimmung der Entfernung und Annäherungsgeschwindigkeit

Benefits für ausgewählte ADAS-Funktionen



ACC Stopp&Go inkl. Querführung

- **Kamera:** Spurhaltung unter Berücksichtigung Position Vorderfahrzeug
- **Radar:** Exakte Bestimmung der Entfernung und Relativgeschwindigkeit
- **Kamera & Radar:** Freiraumüberwachung, Redundanz

Unterschiedliche Sensorprinzipien realisieren verschiedene Messanforderungen



Stereo-Videokamera (Diverse)

- Textur der Umgebung (SW)
- Tiefeninformation bis typ. 30 - 50 m
- Erfassungsbereich ca. 30°
- Winkelauflösung typ. 0,05°
- Messfrequenz typ. 25 Hz



Mono-Videokamera (Diverse)

- Textur der Umgebung (SW)
- Erfassungsbereich 30° - 60°
- Winkelauflösung typ. 0,05°
- Messfrequenz typ. 25 Hz



Radar (A.D.C ARS 300)

- Entfernungs- /
Geschwindigkeitsmessung
- Reichweite bis ca. 150 m



Laserscanner (IBEO LUX)

- Entfernungsmessung (Profil)
- Großer Erfassungsbereich (100°)
- Typ. Winkelauflösung (0,25°)
- Messfrequenz 25 Hz
- Reichweite bis ca. 100 m



Weitere Informationsquellen ergänzen das Gesamtbild



Kommunikation

- WLAN basiert
- Fahrzeug-Fahrzeug
- Fahrzeug-Infrastruktur



DGPS / RTK-GPS

Absolute Positionierung
mittels Satellitennavigation
RTK-Referenz, Genauigkeit
bis 5 cm absolut möglich



Inertialsensorik

- Erfassung Fahrdynamik
- Eigenbewegungsschätzung



Digitale Karte

- Genaue Positionierung
im Verkehrskontext
- Datenbasis für Situations-
analyse



Informationsfusion hat unterschiedliche Ausprägungen

Informationen der Datenquellen:

Sensor 1

Sensor 2

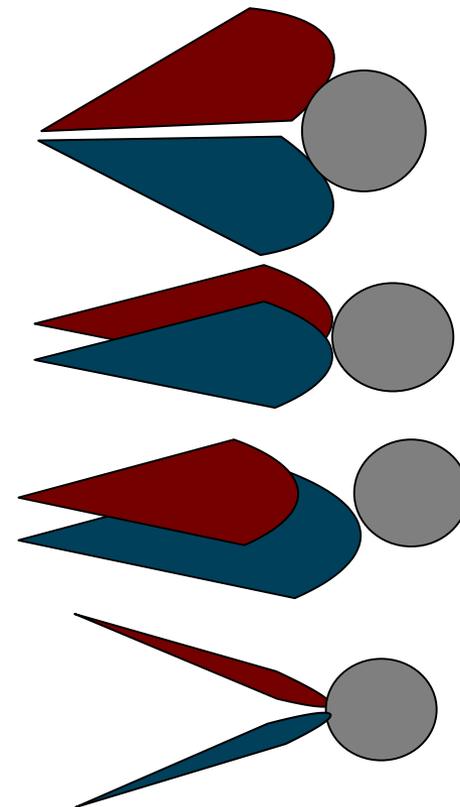
Objekt

komplementär - ergänzend

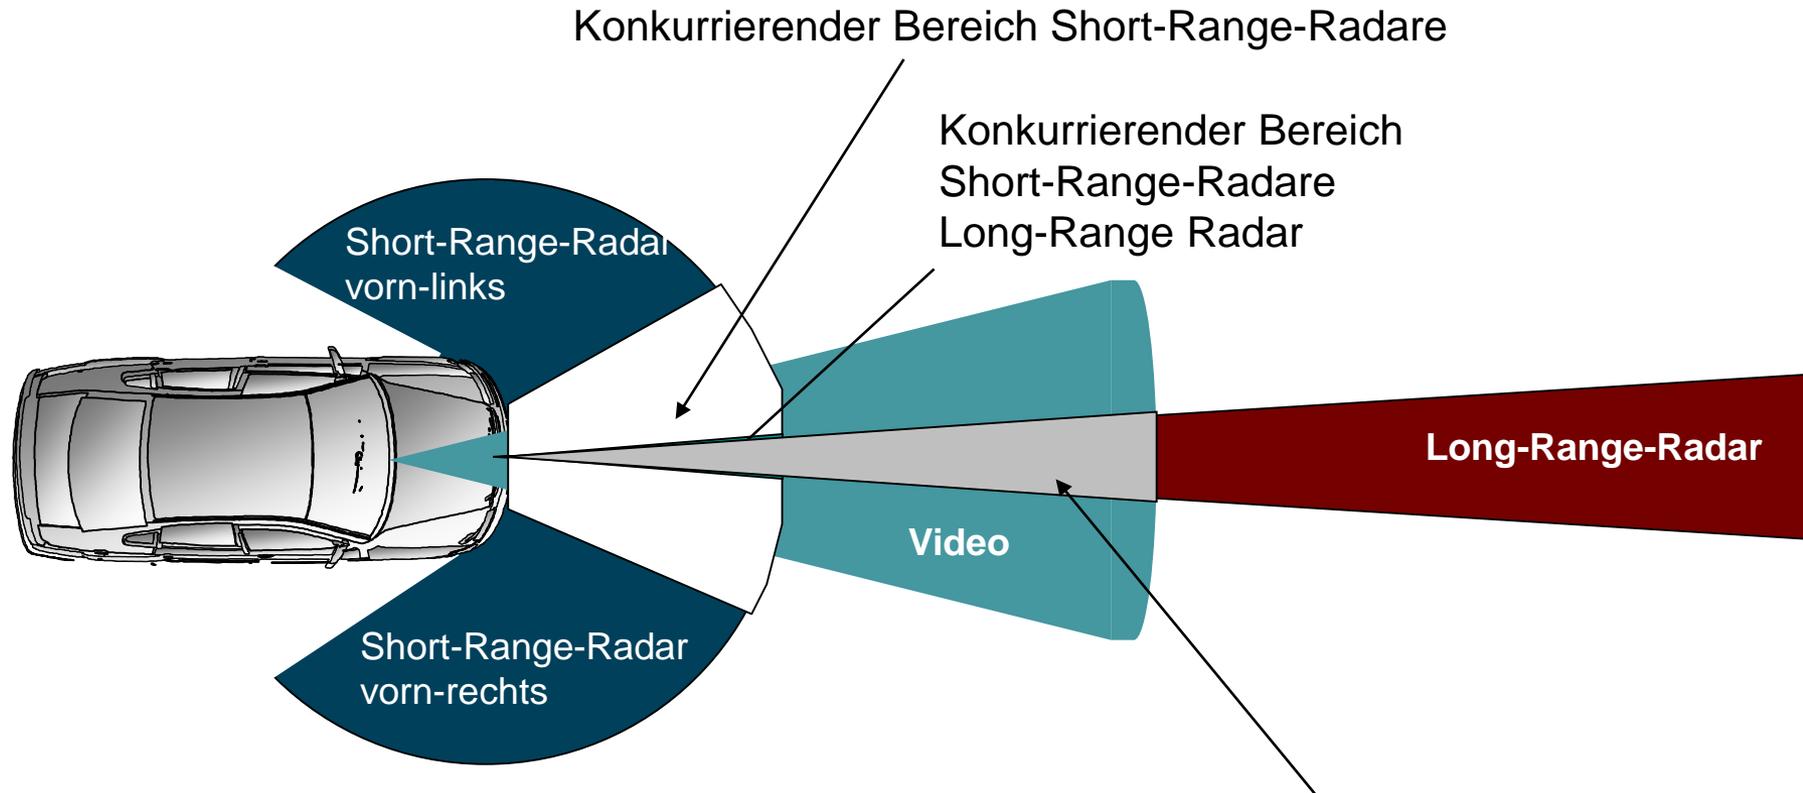
konkurrierend - redundant

- konträr

kooperativ - qualitätssteigernd



Beispiel: Fusion von Videokamera, Long-Range Radar, 2 Short-Range Radare

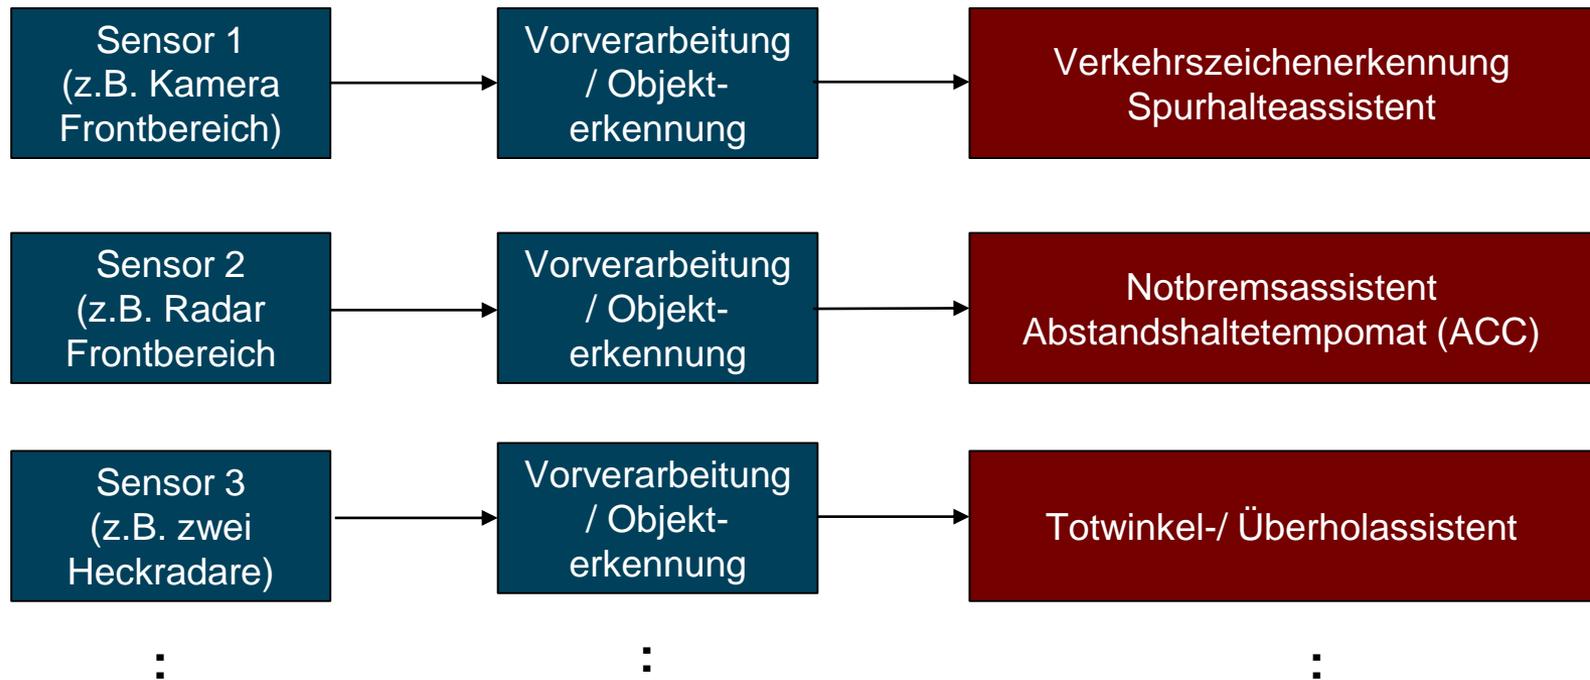


Informationen der Datenquellen:

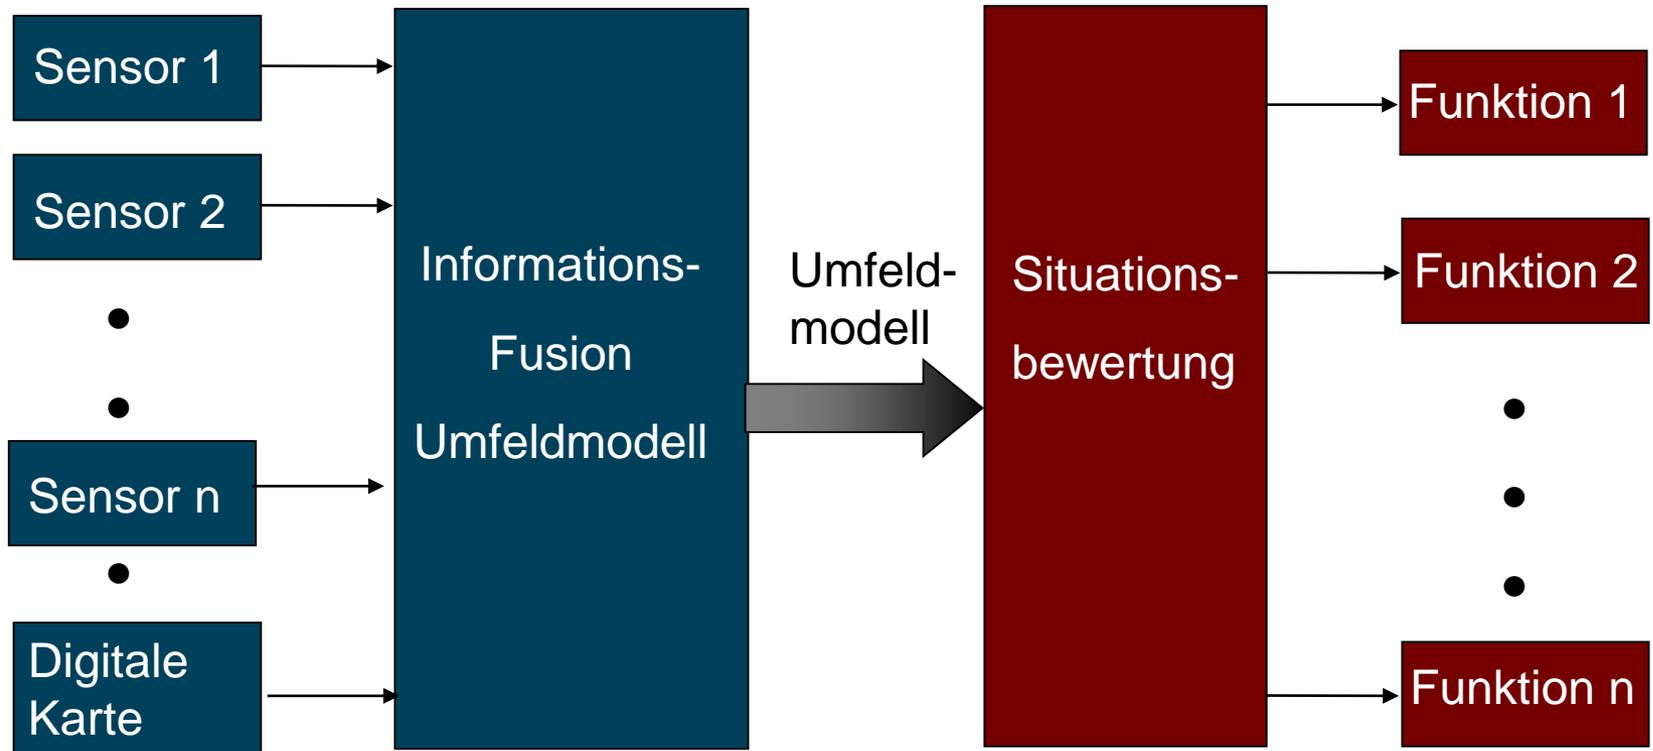
- | | |
|---------------|----------------------|
| komplementär | - ergänzend |
| konkurrierend | - redundant |
| | - konträr |
| kooperativ | - qualitätssteigernd |

Komplementärer Bereich Long-Range Radar
Video (teilweise Short-Range Radare)

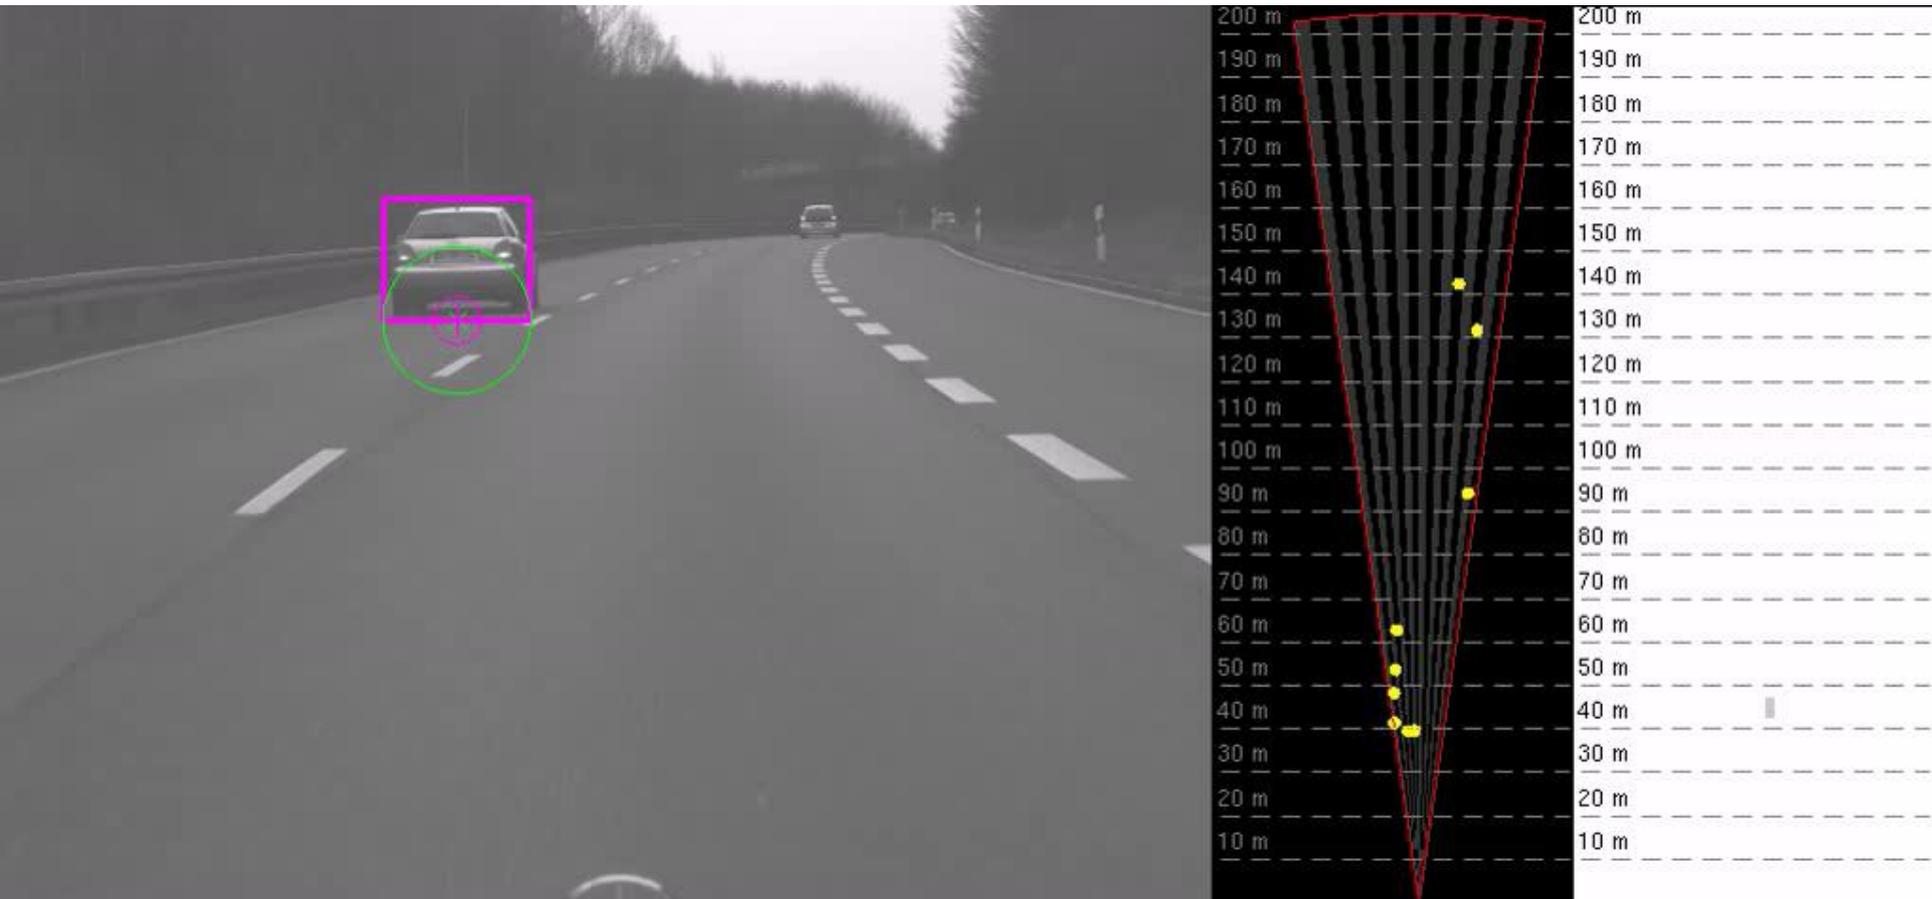
Bisher vorherrschende funktionale Architektur bei ADAS-Funktionen stößt an ihre Grenzen



Komplexere Funktionen erfordern aus technischer und wirtschaftlicher Sicht eine generische Informationsfusion



Beispielszene: Fusion Lidarmessung (Feststrahl) mit einem Rückfronten-Videoklassifikator



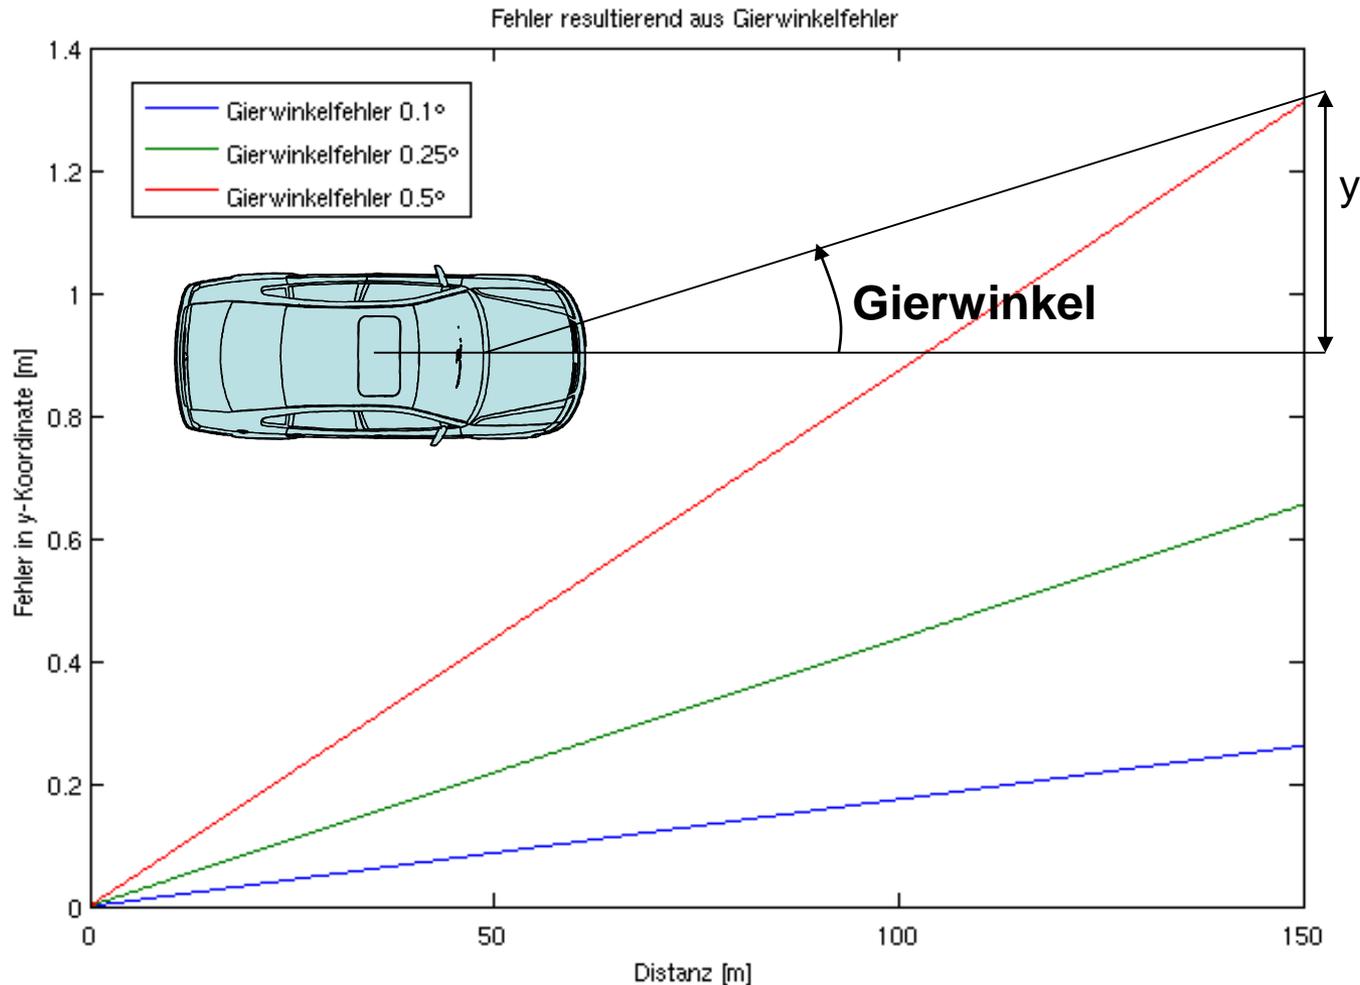
Sensorfusion erfordert eine räumliche und zeitliche Kalibrierung der Sensoren

Räumliche Kalibrierung Ermittlung der Transformationsbeziehungen (jeweils 6 Freiheitsgrade) unter Nutzung geeigneter Kalibrierobjekte

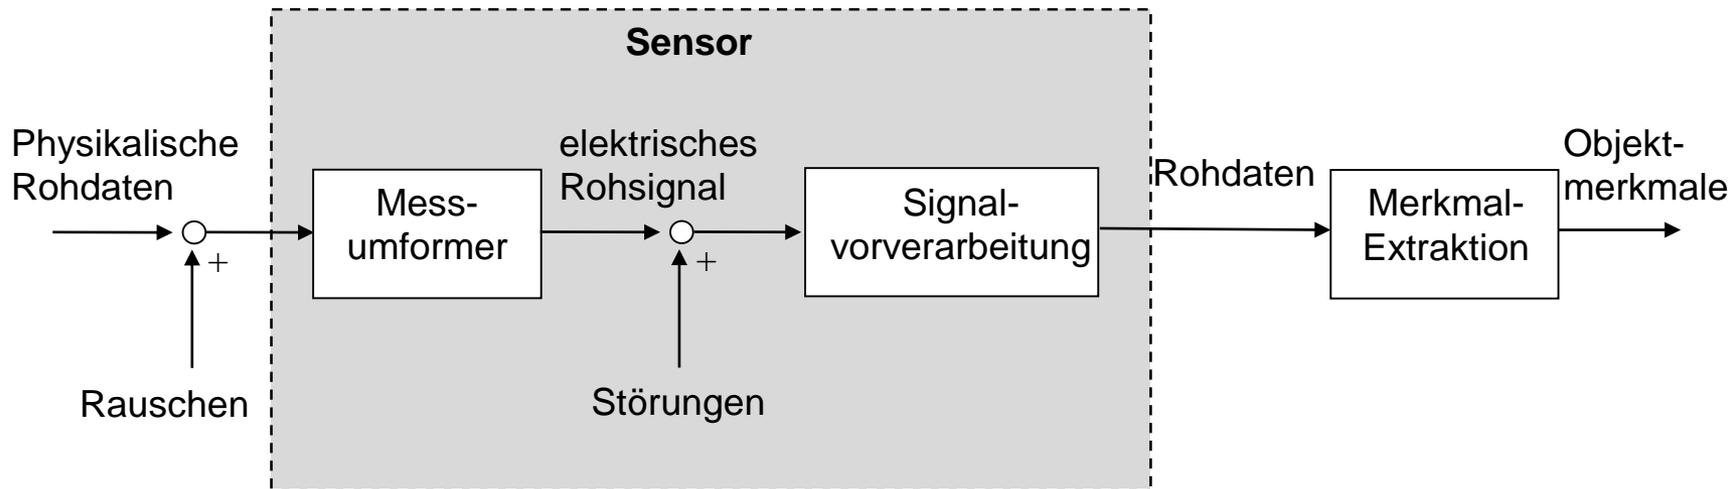


Beispiel: Sensorfusionssystem bestehend aus Kamera und Radar

Geringe Gierwinkelfehler führen in der Entfernung zu großen Positionsabweichungen



Bis die Sensormessung im Fusionssystem vorliegt, vergeht eine Latenzzeit, Modell der Messwerterfassung



Beispiel Video-Kamera als Sensor:

Elektro-
magnetische
Strahlung

CMOS-Chip /
CCD-Chip

Ladungen /
Spannungen
pro Pixel

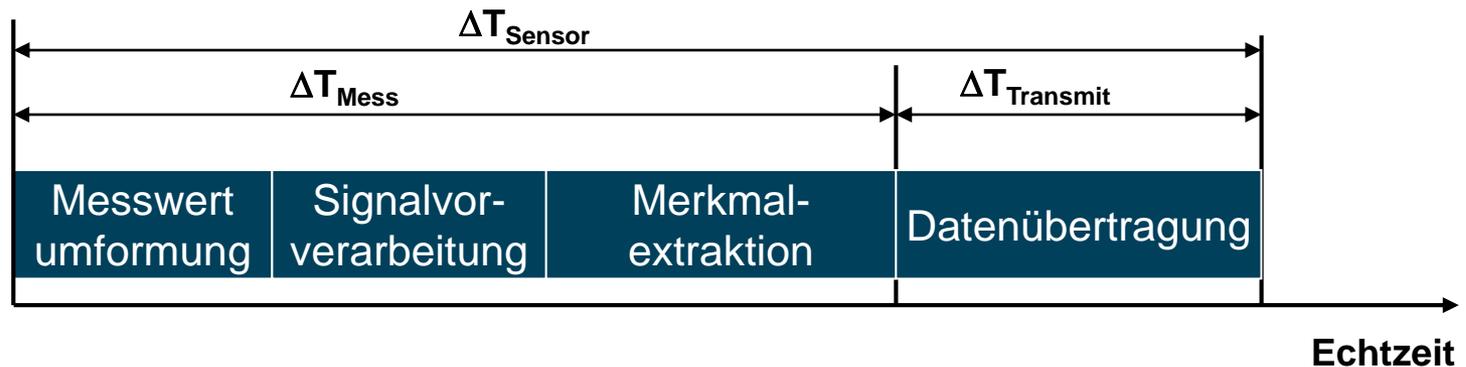
Verstärkung
/Digitalisierung
/Filterung

Digitales
Bild

Fahrzeug
Klassifikator

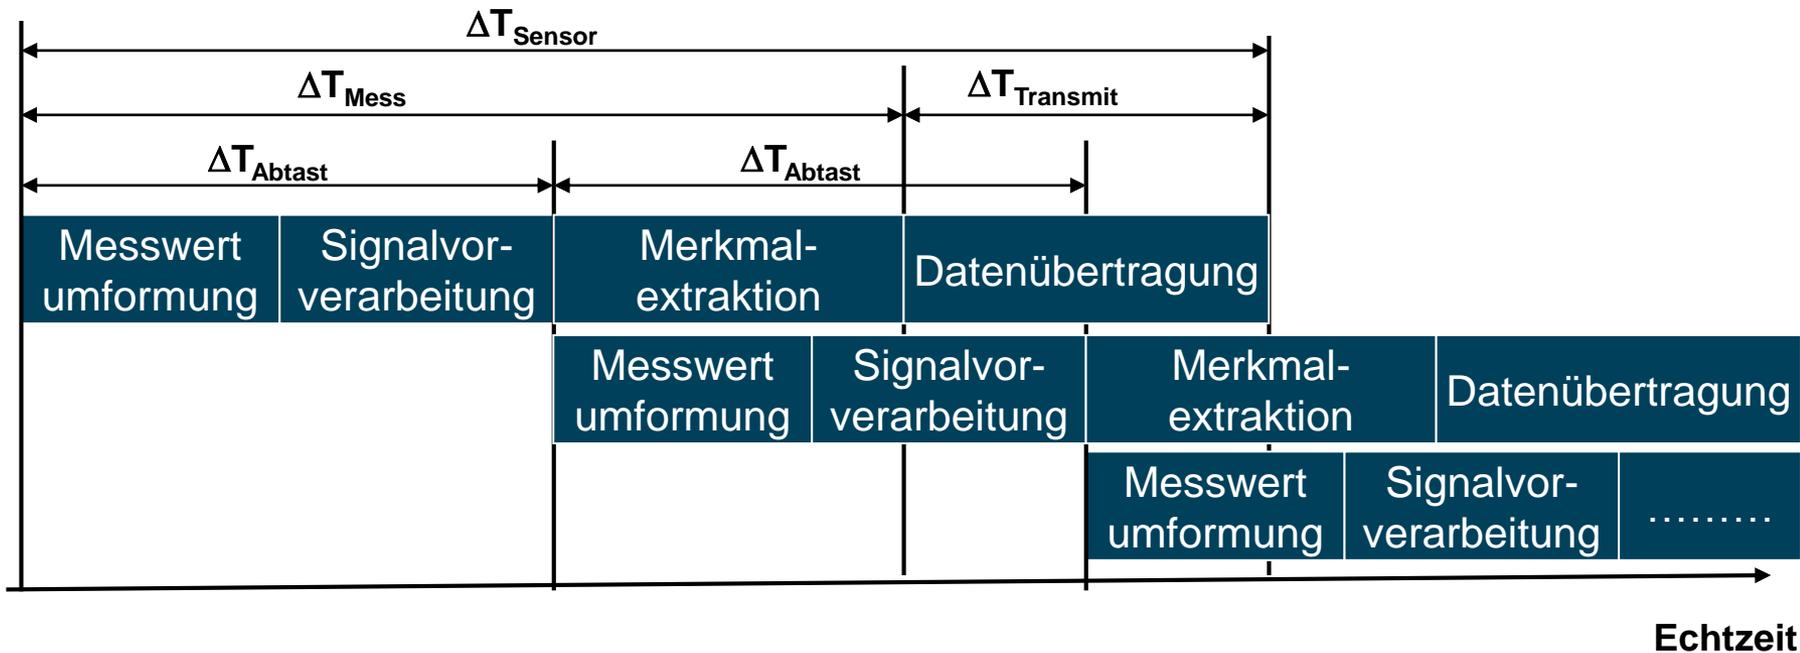
Fahrzeug-
Positionen
im Bild

Zwischen Realwelt und Verfügbarkeit der Messinformation besteht immer eine Latenz



$$\begin{aligned} & \Delta T_{\text{Sensor}}: && \text{(Latenzzeit des Sensors / Alter der Messung)} \\ = & && \\ & \Delta T_{\text{Mess}} && \text{(Messzeitpunkt bis Merkmalgenerierung)} \\ + & && \\ & \Delta T_{\text{Transmit}} && \text{(Übertragungszeit zum Sensorfusionssystem)} \\ & && \text{(z.B. CAN-Bus, Flexray, etc.)} \end{aligned}$$

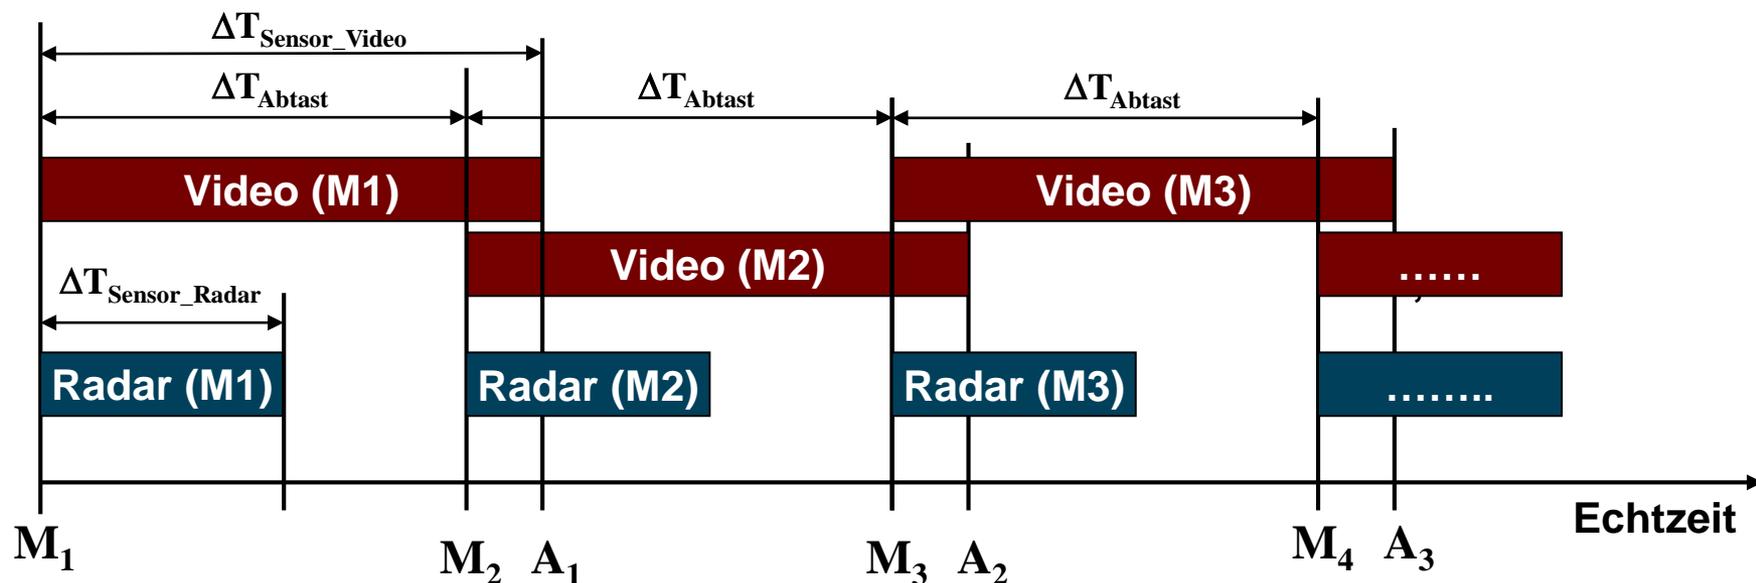
Zeitliche Verzahnung sichert eine möglichst hohe Abtastfrequenz, die Latenzzeit des Sensors bleibt gleich



Latenzzeit ΔT_{Sensor} versus Abtastzeit ΔT_{Abtast}

Relation der Größen zueinander sowie Absolutwerte sind sensorspezifisch!

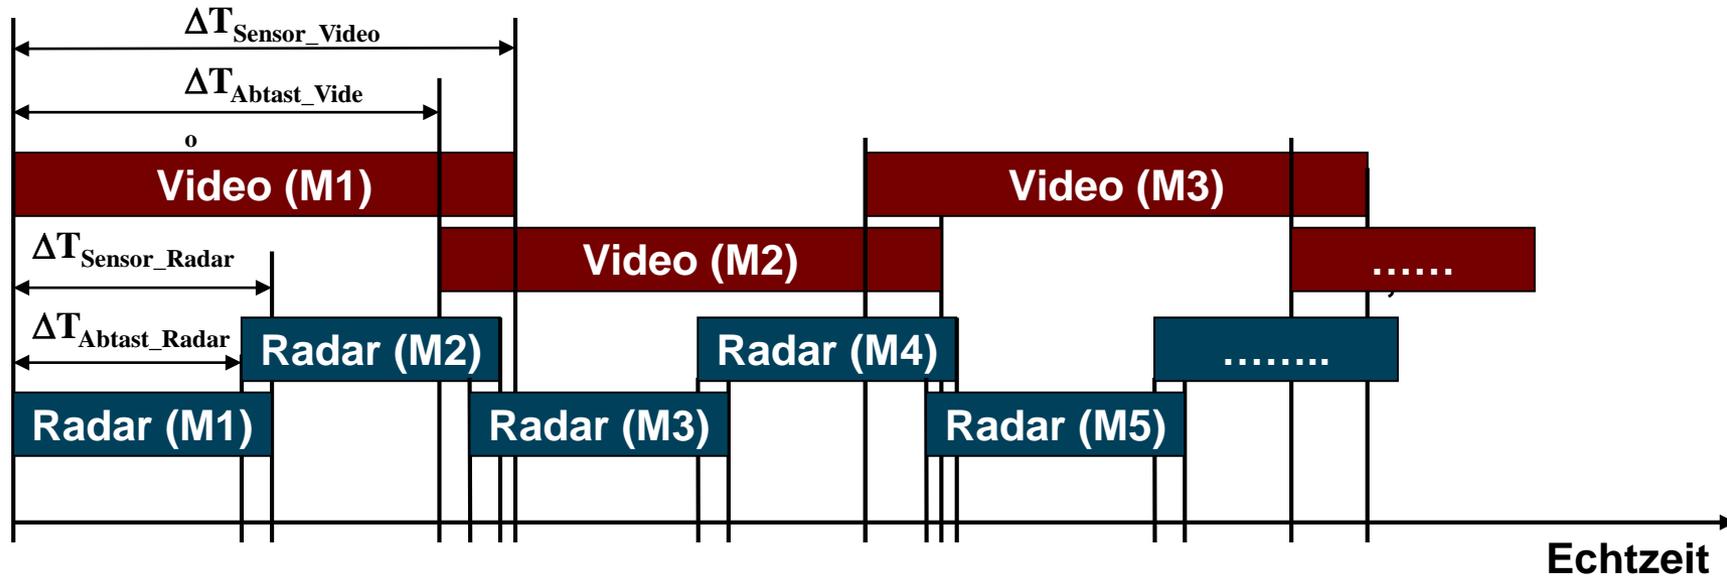
Ein synchrones Fusionssystem sichert die zeitliche Konsistenz der zu verarbeitenden Sensormessungen



M_i : Messzeitpunkte, bei synchronem System für alle Sensoren identisch
 A_i : Auswertzeitpunkte, Werte aller Sensoren stehen zur Verfügung

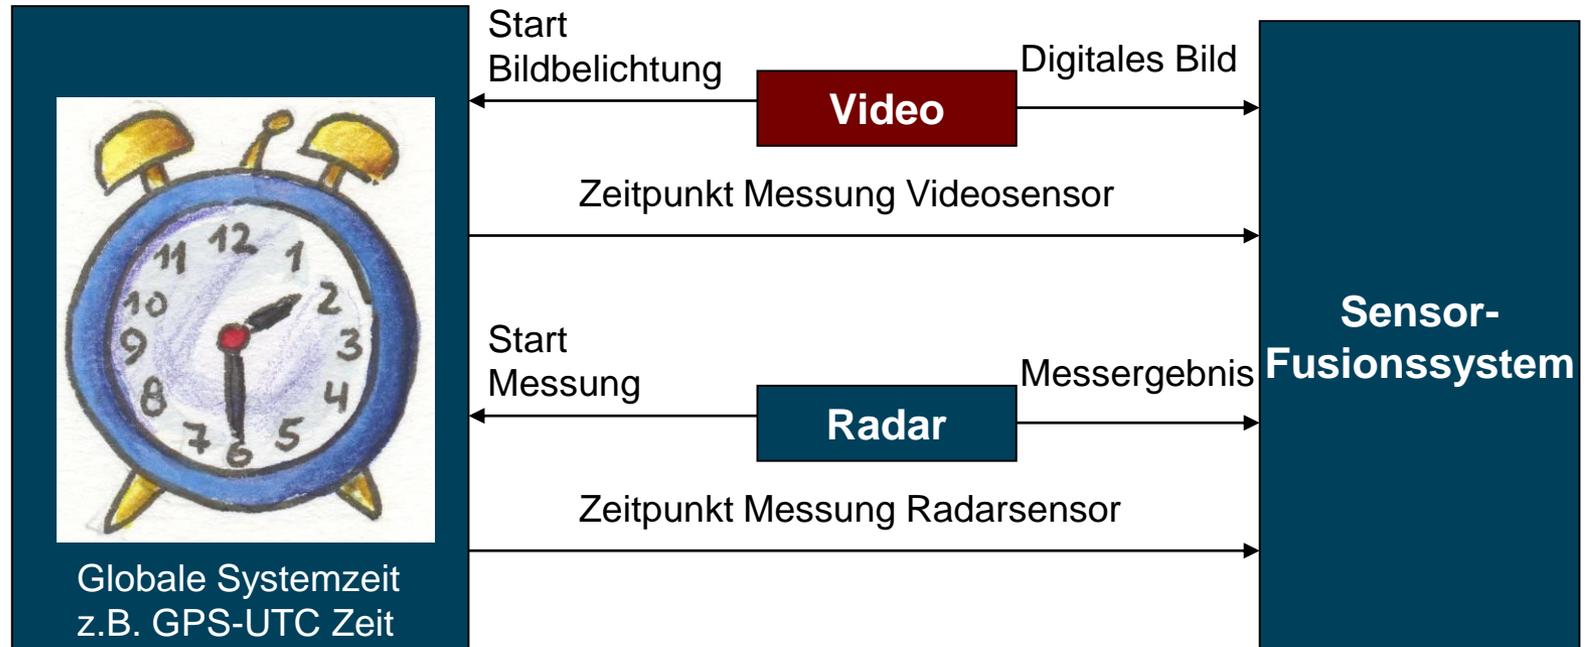
Die Latenzzeit des langsamsten Sensors bestimmt die Latenzzeit zwischen Messzeitpunkt und Auswertzeitpunkt im System

Bei asynchronen Fusionsarchitekturen kann es zu Inkonsistenzen in der Messreihenfolge kommen



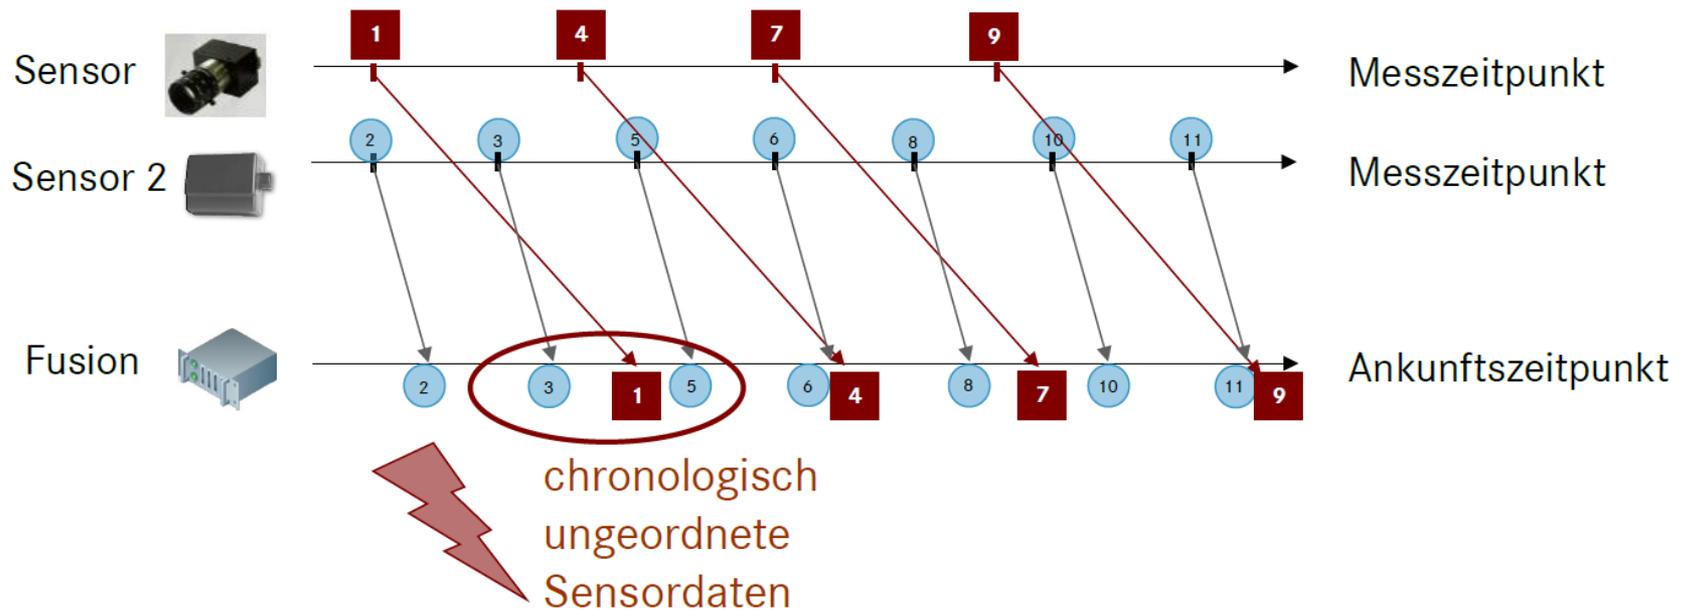
- Reihenfolge der Messergebnisverfügbarkeit nicht notwendig zeitlich konsistent mit Reihenfolge Messerfassung
- Keine gemeinsamen deterministischen Messzeitpunkte
- Zur nachträglichen Ordnung der Daten Zeitstempelungsverfahren notwendig, da Filteralgorithmen nicht zeitlich inkonsistente Daten fehlerfrei verarbeiten können !

Zeitstempelung ermöglicht die zeitliche Einordnung eintreffender Messergebnisse

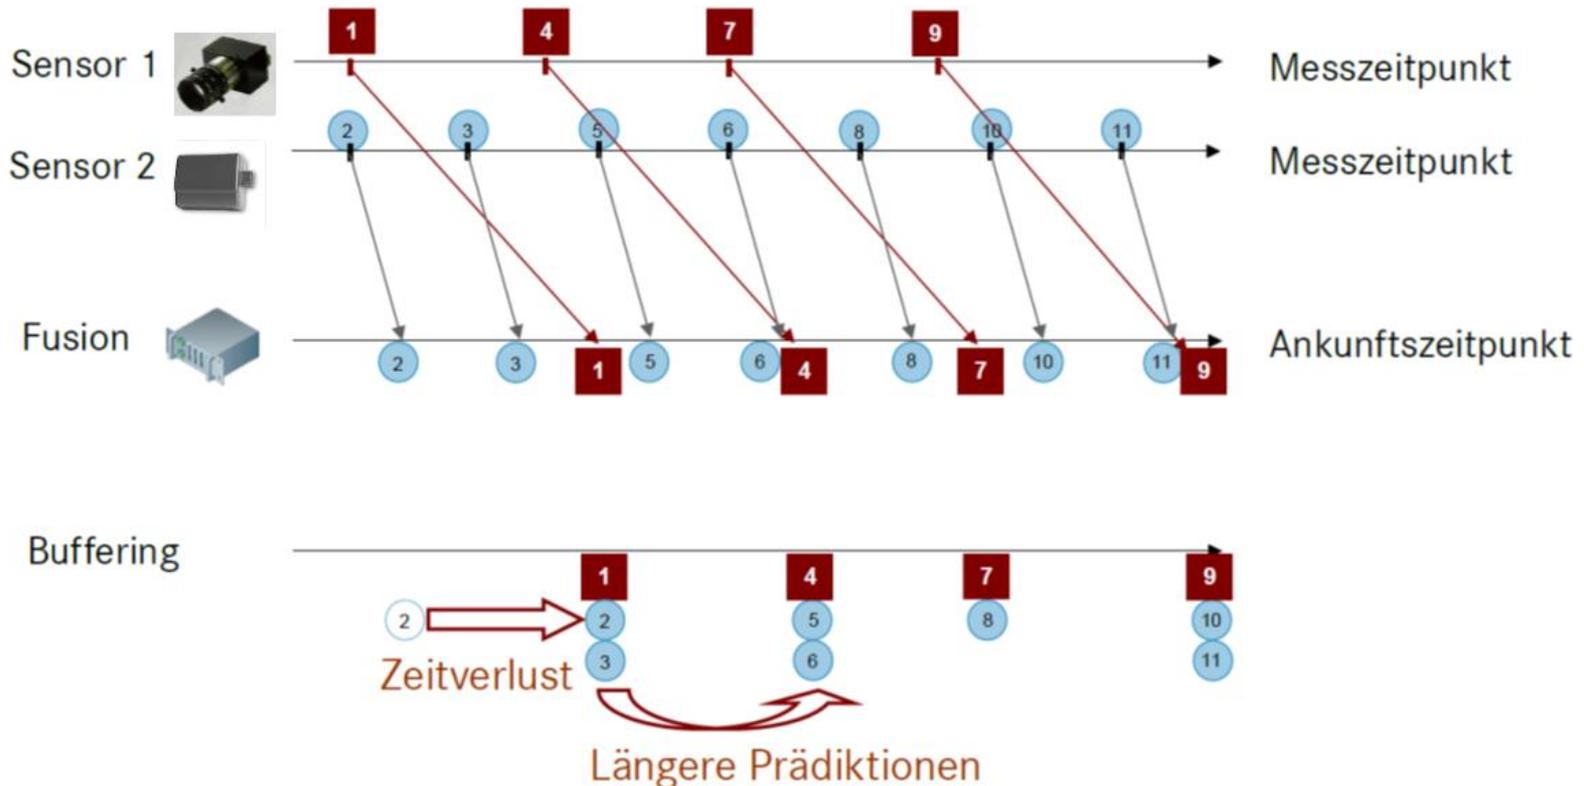


- Häufig keine Verfügbarkeit der Signale „Messstart“ an den Sensoren
- Keine Triggerbarkeit der Sensoren (synchrones System unmöglich)
- Lösungen bei Zulieferern einfordern !!

Verlust der zeitlichen Kausalität bei asynchron laufenden Sensoren (Out of Sequence Measurements)

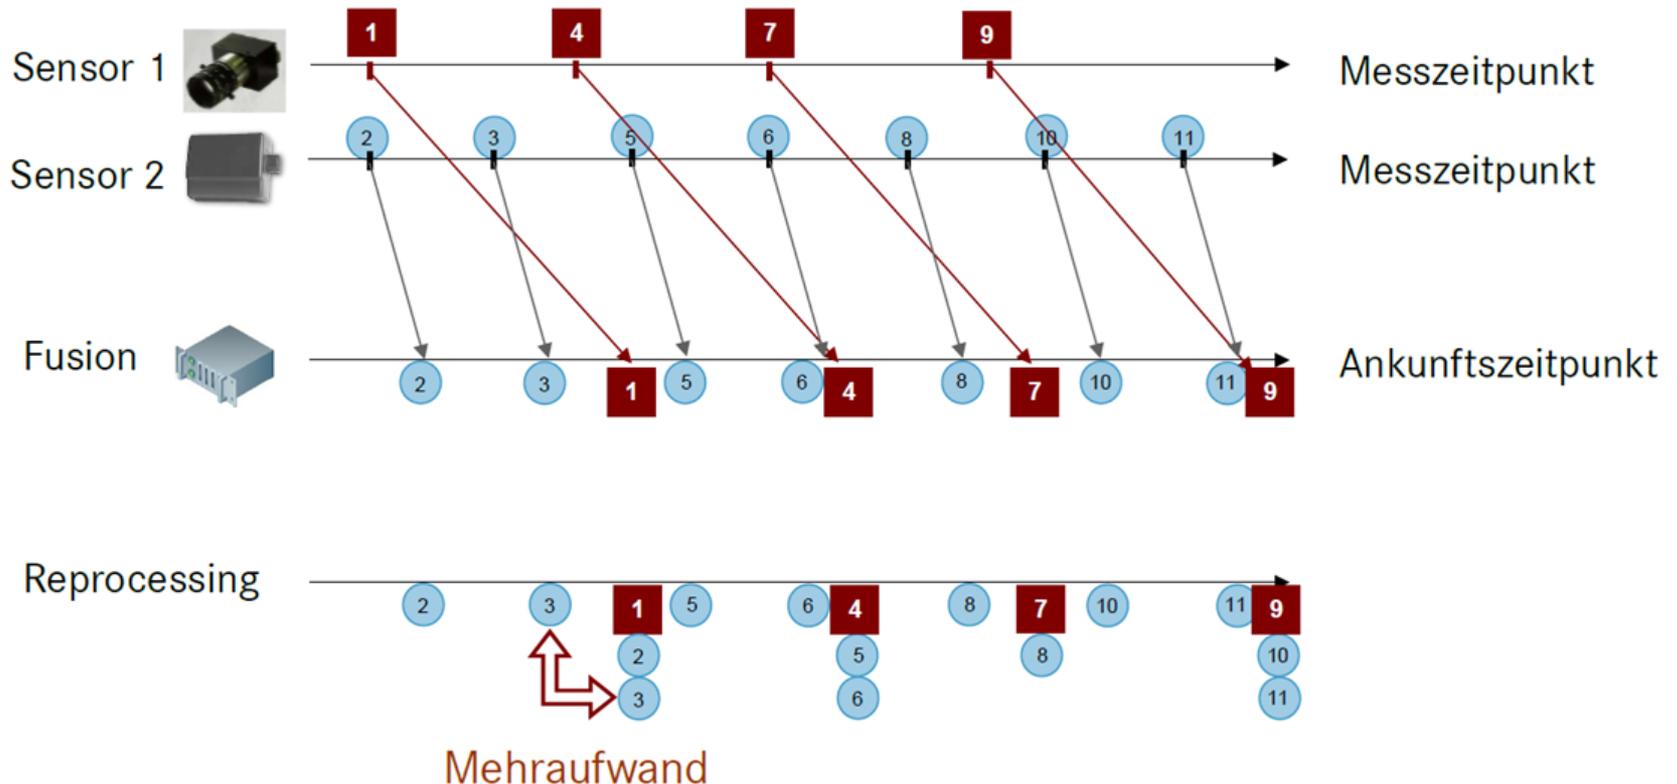


Buffering: Es sichert zeitliche Konsistenz, führt aber zu einer größeren Latenz zwischen Realwelt und Umfeldmodell



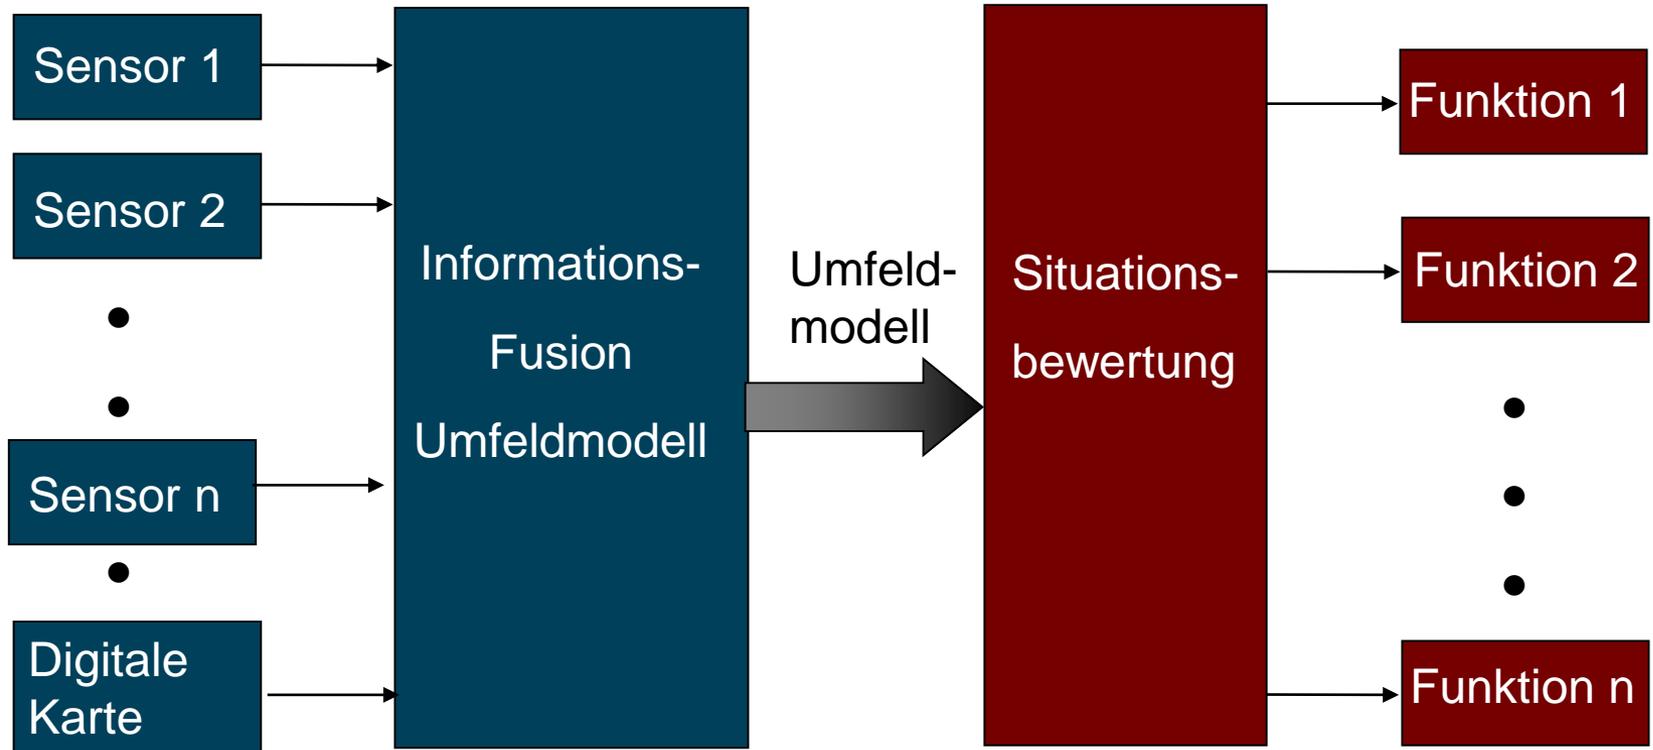
Buffering ist dann effektiv, wenn die Latenzen der verwendeten Sensoren ähnlich sind.

Reprocessing: Ist die exakteste Methode bei asynchronen Sensoren, eine zeitliche Konsistenz sicherzustellen

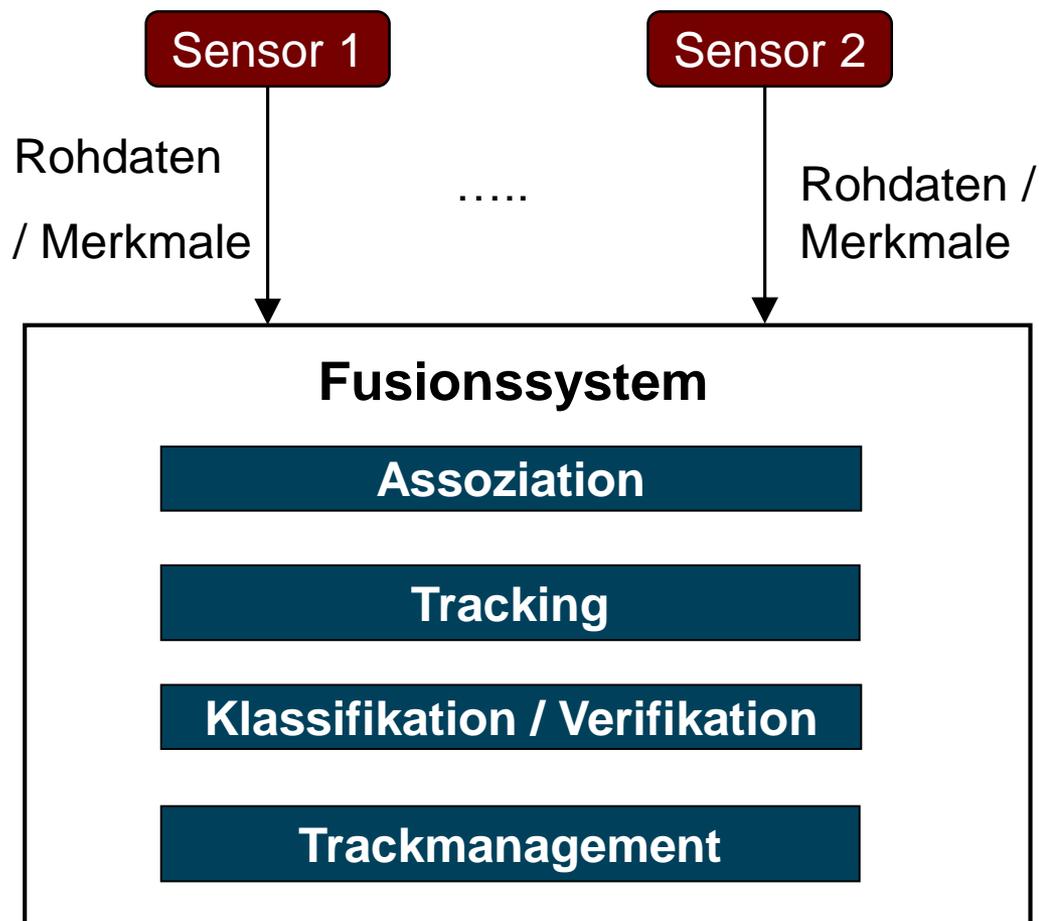


Reprocessing erfordert einen erheblichen Rechenmehraufwand, da „alte“ Messungen mehrfach verarbeitet werden müssen.

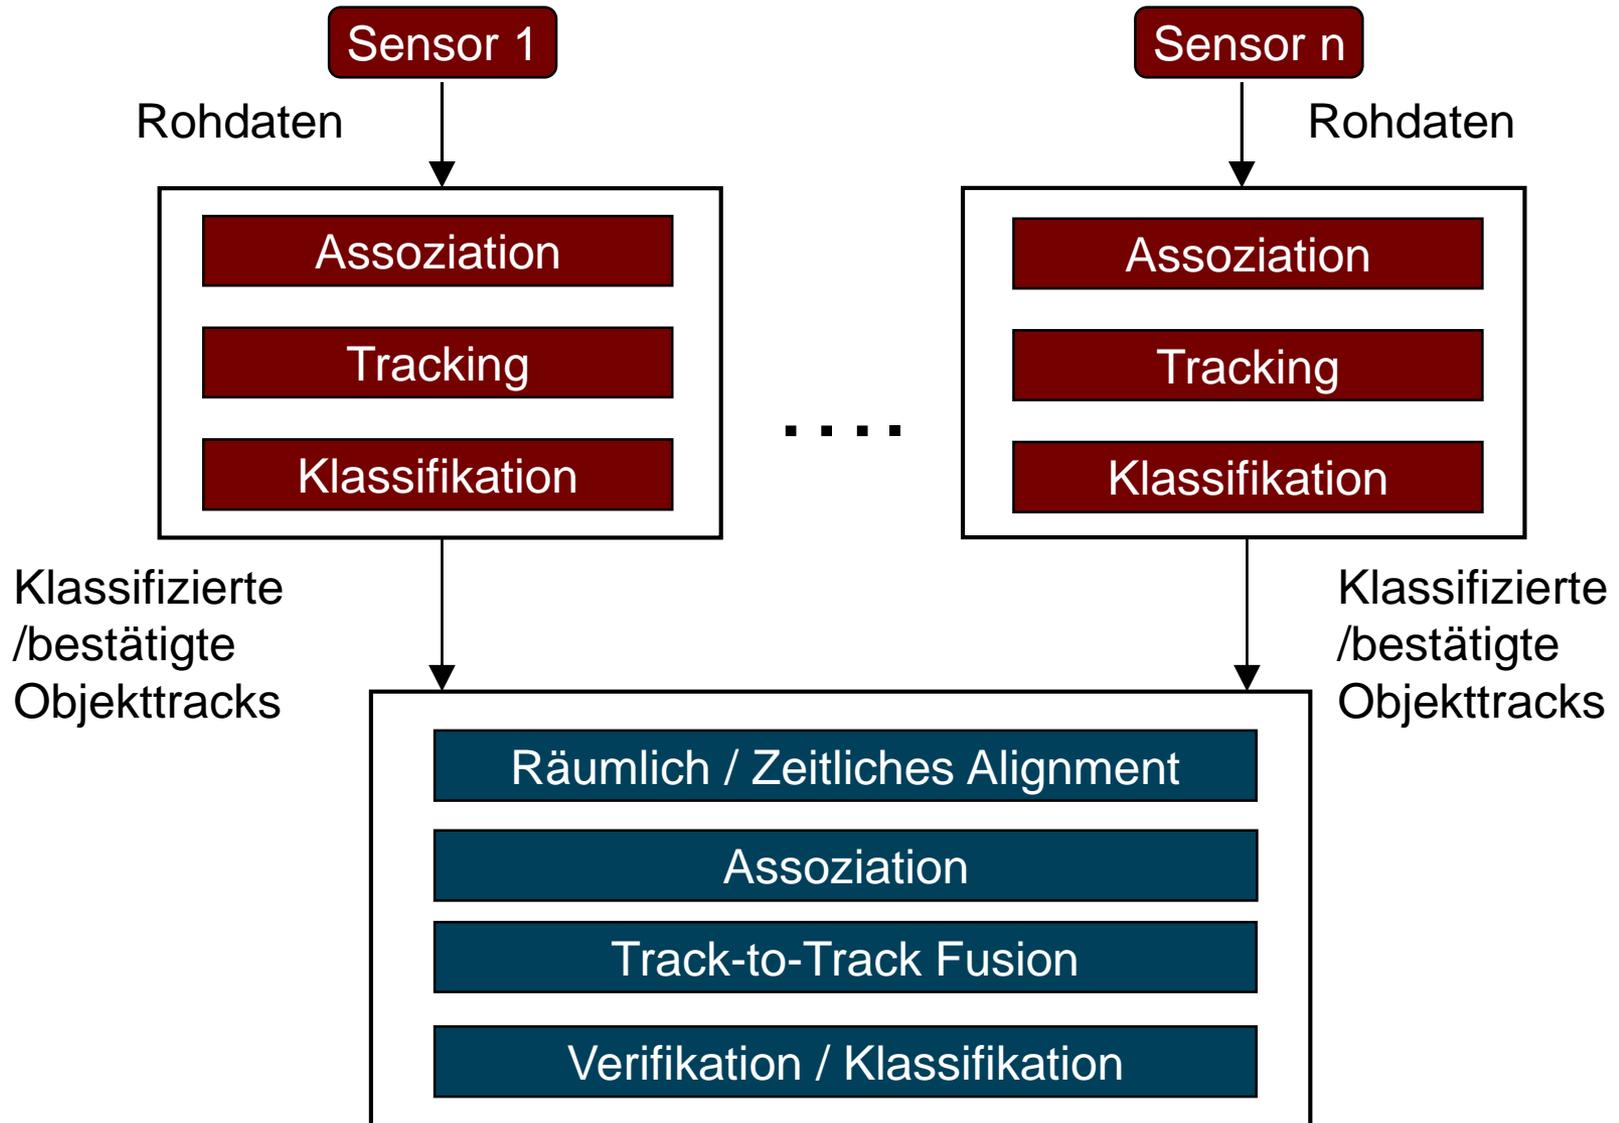
Architektur Aspekte der Informationsfusion



Zentrale Fusionsarchitektur Low-Level / Feature Level Fusion



Dezentrale Fusionsarchitektur



Literatur / Matlab-Code

- Grundlagen:
 - Bücher von Y. Bar-Shalom
 - S. Blackman: „Design and Analysis of Modern Tracking Systems“
- B. Ristic: „Beyond the Kalman Filter“
- B.-N. Vo et. al: „Multitarget Tracking“, http://ba-ngu.vo-au.com/vo/VMBCOMV_MTT_WEEE15.pdf
- Multi-Objekt-Tracking mit Random Finite Sets:
 - R. Mahler: „Statistical Multi-Source Multi-Target Information Fusion“
 - R. Mahler: „Statistics 101“ / „Statistics 102“
 - S. Reuter: „Multi-Object Tracking Using Random Finite Sets“
<https://oparu.uni-ulm.de/xmlui/handle/123456789/3231>
- K. Granström, M. Baum, S.Reuter: „Extended Object Tracking: Introduction, Overview and Applications“, <https://arxiv.org/abs/1604.00970>
- Matlab Code Multi-Objekt-Tracking: <http://ba-tuong.vo-au.com/codes.html>