

UNIVERSITÄT DER BUNDESWEHR  
FAKULTÄT FÜR LUFT- UND RAUMFAHRTTECHNIK  
INSTITUT FÜR FLUGSYSTEME

# **Realisierung eines Sensor- & Perzeptionsmanagement Systems für unbemannte fliegende Plattformen**

Martin Ruß

Vollständiger Abdruck der von der Fakultät für Luft- und  
Raumfahrttechnik der Universität der Bundeswehr München  
zur Erlangung des akademischen Grades eines

Doktor-Ingenieurs (Dr.-Ing.)

angenommenen Dissertation.

Gutachter:

1. Univ.-Prof. Dr.-Ing. Peter Stütz
2. Univ.-Prof. Dr.-Ing. Helmut Mayer

Diese Dissertation wurde am 15.05.2023 bei der Universität der Bundeswehr München eingereicht und durch die Fakultät für Luft- und Raumfahrttechnik am 22.07.2023 angenommen. Die mündliche Prüfung fand am 25.07.2023 statt.



## Kurzfassung

In Anwendungsgebieten der Überwachung, des Katastrophenschutzes oder der Inspektion sind der flexible und zuverlässige Einsatz von Missionssensoren für bemannte und unbemannte Flugsysteme von großer Relevanz. Aus betriebswirtschaftlichen und operationellen Gründen besteht hierbei der Bedarf, die manuelle Auswertung der Sensordaten zu automatisieren. Der Schritt zu einer der menschlichen Bildauswertung ähnlichen Qualität gestaltet sich allerdings schwieriger als gedacht. Die Herausforderungen sind u.a. sich verändernde Umweltsituationen wie der störende Einfluss dynamischer Licht- und Wetterbedingungen, variierende Einsatzgebiete, die limitierten Ressourcen fliegender Plattformen und die Komplexität der Subsysteme.

Sich ergänzende Sensorarten sowie ein effizienter und an Umgebungsbedingungen angepasster Einsatz der Algorithmen könnten Grundlage einer Lösung sein, die die den jeweiligen Messprinzipien zugrunde liegenden Einschränkungen berücksichtigt und die Güte der Messungen steigert.

Die Fragestellung lautet hierbei:

Wie kann der Einsatz der Missionssensoren sowie eine situationsangepasste Auswertung auf unbemannten Fluggeräten automatisiert werden, so dass auch unter dynamischen Umwelteinflüssen und trotz eingeschränkter Ressourcen eine hohe Leistung der Sensordatenauswertung garantiert werden kann?

Im Rahmen dieser Arbeit wird hierzu ein ganzheitliches Systemkonzept für unbemannte Plattformen vorgeschlagen, das umgesetzt und im Zuge von Flugversuchen evaluiert wurde.

Auf höchster Ebene empfängt das Mission Management System (MMS) Aufträge von den Operateuren und zerlegt sie in Warnungs- und Navigationsaufgaben. Diese Aufgaben werden dann an untergeordnete Teilsysteme weitergeleitet – das Flight Management System (FMS) und das Sensor- und Perzeptionsmanagementsystem (SPMS). Zur Realisierung wurden einerseits Wahrnehmungs- und Sensorfähigkeiten mithilfe von Bayesschen Netzen modelliert, andererseits wurde ein marktbasierendes Kettenmanagement implementiert. Die Auswertung redundanter Kettenmodelle ermöglicht die Adaption an den aktuellen Umweltkontext im Sinne einer Kettenrangfolgebestimmung während des Fluges.

Der Einsatz des SPMS ermöglichte eine automatisierte, ganztägige und ganzjährige Auswertung von Sensordaten unter schwierigen Umweltbedingungen im nominalen Betrieb. Selbst die schlechteste Leistung des SPMS während der Flugversuche erreichte mit einem F2-Score von 89% einen sehr guten Zuverlässigkeitsbereich. Neben dem nominalen Betrieb, konnte mit dem SPMS ein Fail-Operational-Betrieb bei Ausfällen von Sensoren sowie ein ressourcenoptimierter Betrieb ermöglicht und nachgewiesen werden.





## Abstract

In the fields of surveillance, disaster protection, and inspection, the flexible and reliable deployment of mission sensors for manned and unmanned aerial systems is of great relevance. For economic and operational reasons, there's a need to automate the manual analysis of sensor data. However, achieving a quality of image analysis similar to human assessment is proving more challenging than expected. The challenges include changing environmental situations, such as the disruptive influence of dynamic light and weather conditions, varying operational areas, the limited resources of flying platforms, and the complexity of the subsystems.

Complementary types of sensors, along with the efficient and environment-adapted application of algorithms, could form the basis of a solution that takes into account the inherent limitations of each measurement principle and improves the accuracy of measurements.

The question is:

*How can the deployment of mission sensors and situationally adjusted evaluation on unmanned aircraft be automated, ensuring high-quality sensor data evaluation even under dynamic environmental influences and despite limited resources?*

In this context, a system concept for unmanned platforms is proposed, implemented, and evaluated through flight tests.

At the highest level, the Mission Management System (MMS) receives orders from operators and breaks them down into warning and navigation tasks. These tasks are then relayed to subordinate subsystems - the Flight Management System (FMS) and the Sensor and Perception Management System (SPMS). Sensor capabilities were modeled using Bayesian networks, and a market-based chain management was deployed. The evaluation of redundant chain models allows for adaptation to the current environmental context in terms of determining the chain's priority during flight.

The use of the SPMS enabled an automated, day-long, year-round analysis of sensor data under challenging environmental conditions in regular operations. Even the worst performance of the SPMS during the flight tests achieved an F2-Score of 89%, nearing an excellent reliability range. In addition to standard operation, the SPMS also demonstrated a fail-operational mode in the event of subsystem or sensor failures and a resource-optimized operation.



# Inhaltsverzeichnis

<b>KURZFASSUNG.....</b>	<b>3</b>
<b>ABSTRACT .....</b>	<b>5</b>
<b>INHALTSVERZEICHNIS .....</b>	<b>7</b>
<b>1. MOTIVATION UND STRUKTUR DER ARBEIT .....</b>	<b>11</b>
<b>2. HINTERGRÜNDE UND HERAUSFORDERUNGEN .....</b>	<b>15</b>
2.1 LUFTGESTÜTZTE FERNERKUNDUNG UND AUSWERTUNG .....	15
2.2 UNBEMANNTE FLUGSYSTEME .....	18
2.2.1 <i>Einsatz und Anwendungsbeispiele</i> .....	18
2.2.2 <i>Missionsplanung und -durchführung</i> .....	21
2.2.3 <i>Ausgewählte Systemarchitekturen</i> .....	23
2.3 HERAUSFORDERUNGEN KÜNFTIGER ANWENDUNGEN .....	26
<b>3. STAND DER TECHNIK .....</b>	<b>29</b>
3.1 SENSOREINSATZPLANUNG UND SENSORMANAGEMENT .....	29
3.1.1 <i>Prinzipien und Methoden</i> .....	31
3.1.2 <i>Modelle und Architekturen</i> .....	33
3.2 SENSORDATENAUSWERTUNG UND BILDVERARBEITUNG .....	39
3.2.1 <i>Aufgaben der Bildverarbeitung</i> .....	39
3.2.2 <i>Verarbeitungsketten und klassische Bildverarbeitung</i> .....	40
3.2.3 <i>Deep Learning Ansätze</i> .....	41
3.2.4 <i>Vergleich der Methoden</i> .....	43
3.3 ANALYSE BESTEHENDER ARCHITEKTUREN UND METHODEN.....	43
<b>4. ZIELSETZUNG DER ARBEIT .....</b>	<b>45</b>
4.1 ANFORDERUNGEN AN DIE SENSORAUSWERTUNG FÜR UNBEMANNTE FLUGSYSTEME .....	45
4.2 FORSCHUNGSFRAGEN .....	46

---

<b>5. SYSTEMKONZEPT .....</b>	<b>49</b>
5.1 ENTWURF DES GESAMTSYSTEMS .....	49
5.2 VERARBEITUNG VON WAHRNEHMUNGS-AUFTRÄGEN .....	51
5.3 AUSWAHL GEEIGNETER SENSOREN UND ALGORITHMEN .....	52
5.4 VALIDIERUNG VON ERGEBNISSEN .....	54
5.5 ZUSAMMENFASSUNG UND FOKUSSIERUNG .....	54
<b>6. MODELLIERUNG DER KETTENLEISTUNG .....</b>	<b>55</b>
6.1 ZIELE DER KETTENMODELLIERUNG .....	55
6.2 KRITERIEN ZUR METHODENAUSWAHL .....	56
6.3 VERGLEICH UND AUSWAHL EINER METHODE .....	57
6.4 GRUNDLAGEN BAYESSCHER NETZE .....	61
6.4.1 <i>Theorie und Aufbau</i> .....	61
6.4.2 <i>Beispielnetz zur Verdeutlichung</i> .....	63
6.5 KONZEPTIONELLE EIGENSCHAFTEN BAYESSCHER NETZ .....	65
6.5.1 <i>Prinzipien und Regeln</i> .....	66
6.5.2 <i>Inferenz- und Schlussfolgerungsmöglichkeiten</i> .....	66
6.5.3 <i>Berechenbarkeit und Komplexität</i> .....	67
6.5.4 <i>Lernfähigkeit</i> .....	68
6.6 KETTENMODELLIERUNG ZUR LEISTUNGSBESTIMMUNG .....	68
6.6.1 <i>3-Phasen-Modellierungsprozess</i> .....	68
6.6.2 <i>Prinzipien der Modellierung</i> .....	70
6.6.3 <i>Kernelemente der Modellierung</i> .....	70
6.6.4 <i>Spezialisierung und Adaption von Ketten</i> .....	72
6.6.5 <i>Diskretisierung und hybride Bayessche Netze</i> .....	74
6.6.6 <i>Einflussfaktoren und Modellierungsvorlage</i> .....	75
<b>7. AUSWAHL VON KETTEN .....</b>	<b>77</b>

---

7.1	KETTENMANAGEMENT .....	77
7.1.1	<i>Koordination von Ketten</i> .....	77
7.1.2	<i>Rangfolgeerstellung von Ketten</i> .....	79
7.1.3	<i>Monitoring und Neubewertung</i> .....	80
7.2	MULTIKRITERIELLE KETTENBEWERTUNG .....	83
7.2.1	<i>Optimierungsaufgabe</i> .....	83
7.2.2	<i>Herleitung der eingesetzten Bewertungsfunktion</i> .....	83
7.2.3	<i>Eigenschaften der eingesetzten Bewertungsfunktionen</i> .....	85
7.2.4	<i>Grenzwertvorgaben zur Vorauswahl von Ketten</i> .....	86
7.3	VORABVALIDIERUNG SYSTEMISCHER FUNKTIONALITÄTEN .....	87
<b>8.</b>	<b>EXPERIMENT UND FLUGVERSUCHE</b> .....	<b>95</b>
8.1	EVALUIERUNGSKONZEPT .....	95
8.1.1	<i>Prüfbare Funktionalitäten</i> .....	95
8.1.2	<i>Untersuchungsgegenstände</i> .....	96
8.2	VERSUCHSPLANUNG DES BEISPIELSZENARIOS .....	99
8.3	FLUGVERSUCHSTRÄGER .....	100
8.3.1	<i>Unbemanntes Fluggerät (Okto-XL)</i> .....	101
8.3.2	<i>Sensor-Rechner Nutzlast (SOMA)</i> .....	103
8.4	KETTENIMPLEMENTIERUNG .....	105
8.4.1	<i>Auswahl der Architektur</i> .....	105
8.4.2	<i>Varianten für kleine Fluggeräte</i> .....	105
8.4.3	<i>Kettensetup und Training</i> .....	106
8.5	VERSUCHSDURCHFÜHRUNG .....	107
<b>9.</b>	<b>AUSWERTUNG UND ERGEBNISBEWERTUNG</b> .....	<b>111</b>
9.1	SCHEMA DER VERSUCHSAUSWERTUNG .....	111
9.2	UNTERSUCHUNGEN ZUR ANPASSUNGSMÖGLICHKEIT VON KETTEN .....	113

---

9.2.1	<i>Generische und effiziente Ketten</i> .....	113
9.2.2	<i>Spezialisierte EO-Ketten für schwierige Bedingungen (Corner-Case)</i> .....	120
9.2.3	<i>Spezialisierte EO-Ketten zur Optimierung (Edge-Case)</i> .....	126
9.2.4	<i>Spezialisierte IR-Ketten für schwierige Bedingungen (Corner-Case)</i> .....	131
9.2.5	<i>Spezialisierte IR-Ketten zur Optimierung (Edge-Case)</i> .....	138
9.2.6	<i>Schlussfolgerungen für Modellierung und Einsatz spezialisierter Ketten</i> .....	144
9.3	<b>MEHRWERT EINER SPMS-UMSETZUNG UNTER REALISTISCHEN BEDINGUNGEN</b> .....	145
9.3.1	<i>Nominaler Betrieb</i> .....	145
9.3.2	<i>Fail-Operational Betrieb</i> .....	149
9.3.3	<i>Betrieb bei Ressourcenknappheit</i> .....	151
<b>10.</b>	<b>ZUSAMMENFASSUNG</b> .....	<b>155</b>
10.1	<b>BEANTWORTUNG DER FORSCHUNGSFRAGEN</b> .....	155
10.1.1	<i>Konzeptionelle Ausarbeitung</i> .....	155
10.1.2	<i>Methodenauswahl und Umsetzung</i> .....	156
10.1.3	<i>Realisierung und Erprobung im Flugversuch</i> .....	157
10.2	<b>AUSBlick</b> .....	158
	<b>EIGENE VERÖFFENTLICHUNGEN</b> .....	<b>161</b>
	<b>MÖGLICHES ANWENDUNGSSZENARIO</b> .....	<b>163</b>
	<b>LITERATURVERZEICHNIS</b> .....	<b>165</b>

# 1. Motivation und Struktur der Arbeit

Der erfolgreiche Einsatz von unbemannten Luftfahrzeugen (engl. *Unmanned Aerial Vehicle*, UAV) ist insbesondere bei Überwachungs- und Aufklärungsmissionen eng mit der Qualität der erfassten Sensordaten und deren verlässlicher Auswertung verbunden. Sowohl die Sensordaten als auch deren Auswertung werden dabei maßgeblich von den vorherrschenden Umweltbedingungen und dem aktuellen Zustand der Sensor- bzw. UAV-Plattform beeinflusst. Abhängig von der Sensorkonfiguration treten die in der Regel negativen Auswirkungen in unterschiedlicher Intensität auf. Diese sind von verschiedenen Faktoren abhängig, wie dem Messprinzip (Wellenlänge) der Sensoren, der zugewiesenen Aufgabe, dem Aufklärungsziel (u.a. Objektdetektion) und dem aktuellen Kontext. Beispiele dafür sind:

- Ungünstige Lichtverhältnisse (zu viel oder zu wenig Licht) oder Bewölkung können unbrauchbare Sensorausgangsdaten zur Folge haben.
- Große Flughöhen können zu schlecht aufgelösten Bildern oder zu nicht messbaren Ergebnissen bei reichweitenbeschränkten Sensoren (u.a. LIDAR) führen.
- Hohe Fluggeschwindigkeiten verursachen aufgrund der Bewegungsunschärfe bei wenig Licht verschwommene Aufnahmen.

Jedoch können wie in Abb. 1 gezeigt selbst für ungünstige Konstellationen aus Umgebung und Plattformzustand durch geschickte Sensorkonfigurationen akzeptable Ergebnisse erreicht werden. Um die Datenqualität zu verbessern, können neben der Wahl eines geeigneten Sensortyps auch Parameter wie etwa Belichtungszeit oder Weißabgleich angepasst werden. Der Abbildungsmaßstab, der durch eine Kombination aus Sensorauflösung und Objektivwahl bestimmt wird, kann ebenfalls angepasst werden.

Allerdings erfordern diese manuellen Eingriffe in das System das Fachwissen erfahrener Experten, um sie treffend und schnell durchzuführen. Nicht nur für den kommerziellen Gebrauch von UAVs ist es wichtig, dass sie benutzerfreundlich, wartungsarm, schnell und kostengünstig einsetzbar sind [Depa13, Tapr11, Weze07]. Eine automatische Konfiguration der Sensoren könnte zu einem breiteren Einsatz und zu höheren Erfolgsraten u.a. in Überwachungs- und Aufklärungsmissionen führen.

Die Auswertung von Sensordaten kann grundsätzlich nach dem Flug erfolgen oder in Echtzeit während des Flugs durchgeführt werden. Während die Offline-Auswertung nach dem Flug keine oder kaum Ressourcen auf dem Fluggerät erfordert, ist die Online-Auswertung während des Flugs aufgrund ihrer Echtzeitfähigkeit und der schnellen Verfügbarkeit der Ergebnisse oft wünschenswerter. Einige Beispiele hierfür sind militärische Aufklärung, Grenz-, Katastrophen- und Umweltschutz bei Überwachungsmissionen sowie Inspektionen von Anlagen, Pipelines oder Stromleitungen.

Auch beim autonomen Einsatz von unbemannten Fluggeräten ist in verschiedenen Missionsphasen wie Situationsanalyse, Planung und Überwachung eine Echtzeit-Auswertung der Sensordaten von großer Bedeutung.



**Abb. 1:** Vorteile durch Wechsel des Sensorprinzips je nach Aufgabe und Umweltkonstellation: Personenerkennung mittels Infrarotsensor (links unten, [GaBH11]), Hinderniserkennung mittels LIDAR (mittig unten, [Kend12]) sowie zur Brandherdlokalisierung im SWIR-Sensorbild (*Short-Wave Infrared*, rechts unten, [Dawe09]).

Für künftige autonome Flugsysteme wird dem Zusammenspiel zwischen automatischer Sensordatenauswertung und intelligenten Teilsystemen zur Flug- und Missionsdurchführung essenzielle Bedeutung zugesprochen. Bestehende Architekturen und Ansätze reichen dabei nicht aus, um den Wirkkreis zur Führung künftiger unbemannter Systeme (Wahrnehmen, Entscheiden, Führen) unter erschwerten Einsatzbedingungen zu schließen. [Depa13, MuSh12].

Je nach Einsatzszenario und zur Reduzierung der Arbeitslast der Operateure sollen UAVs zunehmend automatisiert und später autonom einsetzbar sein. Allerdings benötigen aktuelle UAS zur Missionsdurchführung noch mehrere Operateure. Üblich sind Flugführungs- und Sensoroperateure, Auswerter sowie gegebenenfalls zusätzliches Personal für die Kommunikation.

Es wird also ein innovatives, benutzerfreundliches und ganzheitliches Systemkonzept benötigt, um den Grad der Automation weiter zu steigern.

## Struktur der Arbeit

Obwohl die Datenverarbeitung und Computerarchitekturen in den letzten Jahren beträchtliche Fortschritte gemacht haben, sind viele Anwendungsbeispiele einer automatisierten Sensorauswertung immer noch nicht zuverlässig genug, um unter dynamischen Umwelt- und Flugbedingungen robuste Ergebnisse zu erzielen.

*Warum stellt sich eine automatisierte Sensordatenauswertung auf fliegenden Plattformen unter realen Bedingungen hierbei häufig als schwierig dar?*

Um diese Fragestellung zu verdeutlichen, beschäftigt sich diese Arbeit zunächst mit den hierfür nötigen Grundlagen, Hintergründen und Zusammenhängen zwischen Fernerkundung einerseits und unbemannten Fluggeräten andererseits (Kapitel 2).



*Welche Ziele, Anforderungen und Randbedingungen gilt es zu erfüllen und einzuhalten, um eine robuste, computergestützte Sensordatenauswertung zu ermöglichen, die gerade auch den Trend hin zu intelligenten, autonomen unbemannten Flugzeugen berücksichtigt?*

Nach dem Stand der Technik (Kapitel 3) wird aus der Problemstellung und dem Ziel der Arbeit zunächst ein Anforderungskatalog abgeleitet und Forschungsfragen konkretisiert (Kapitel 4).

Dieser Katalog dient zur Erarbeitung (Kapitel 5) und Evaluierung (Kapitel 9) eines umfassenden Systemkonzepts sowie zur Auswahl geeigneter Methoden (Kapitel 6 und 7), die zur Implementierung eines Prototypen (Abschnitt 7.3) notwendig waren.

Konfiguration, Anpassung, Training sowie Erprobung des Prototyps sollte unter möglichst realen, dynamischen Umgebungs-, Umwelt-, Belichtungs- und Plattformeinflüssen stattfinden. Daher wurde eine Reihe von Flugkampagnen verteilt über wechselnde Jahres- und Tageszeiten unternommen und ausgewertet. In Kapitel 8 sind hierzu die einzelnen Flugkampagnen, die eingesetzten Fluggeräte, eine eigens entwickelte Sensor-Nutzlast sowie die implementierten, CNN<sup>1</sup>-basierten Bildverarbeitungsmodule näher beschrieben.

Die Flug- und Versuchsauswertungen in Kapitel 9 dienen zur Evaluierung des Prototyps [RuSt23] und damit zur Beantwortung folgender Fragen:

*Ist das Systemkonzept tragfähig und umfassend genug? Sind die konkreten Methoden und Algorithmen zur Umsetzung richtig gewählt? Welcher Mehrwert lässt sich bereits aus einer prototypischen Umsetzung im Rahmen einer Anwendung unter realen Bedingungen erzielen?*

Die Arbeit schließt in Kapitel 10 mit einem Resümee und dem Ausblick auf mögliche konzeptionelle sowie methodische Ergänzungen und Änderungen.

---

<sup>1</sup> Convolutional Neural Network



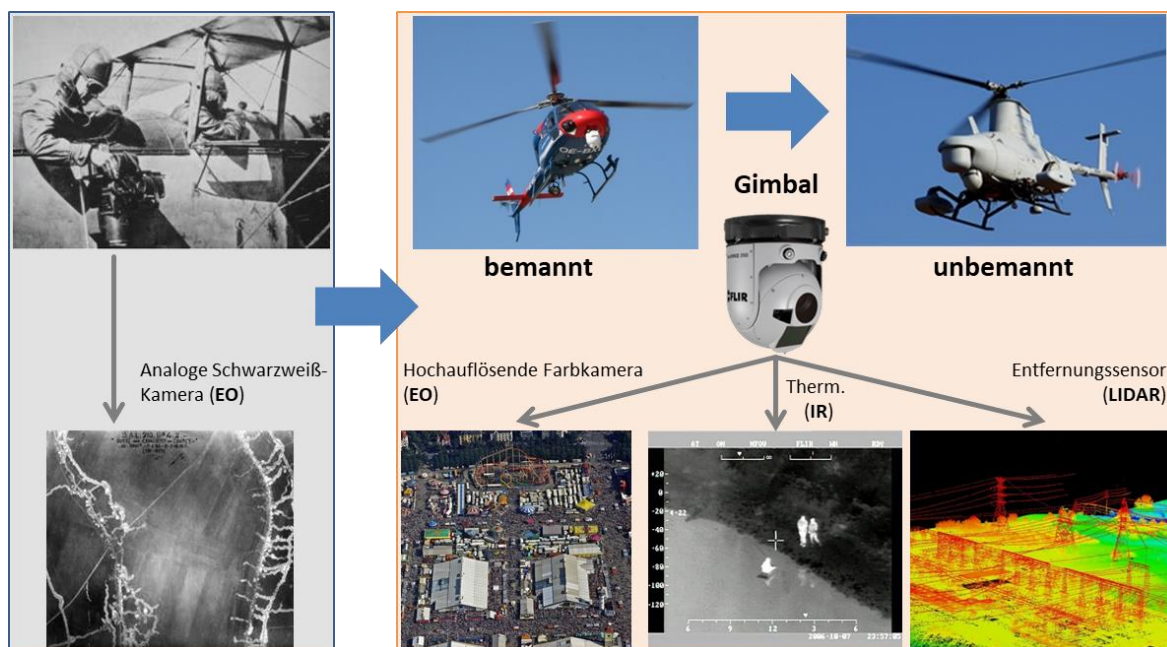
## 2. Hintergründe und Herausforderungen

Zum besseren Verständnis der Fragestellungen aus Kapitel 1 werden die hierfür erforderlichen Grundlagen, Hintergründe zu luftgestützter Fernerkundung, Aufklärung und Überwachung einerseits und unbemannten Fluggeräten andererseits vermittelt.

### 2.1 Luftgestützte Fernerkundung und Auswertung

Das berührungsfreie Beobachten (Erkunden), Messen (Kartieren) und Interpretieren über Distanzen hat eine lange Tradition. Die „Fernerkundung“ (engl. *remote sensing*) war zunächst nur von stationären, exponierten Geländepunkten aus möglich. Flächendeckende Sensordaten hoher Güte lassen sich heutzutage satellitengestützt aus dem Weltraum sowie aus der Luft mittels fliegender Sensorträgerplattformen gewinnen. Hierbei kommen verstärkt unbemannte Flugzeuge zum Einsatz, da diese neben Kostenvorteilen auch operationelle Vorteile bieten (siehe Kapitel 2.2).

Die Nutzung von fliegenden Sensorplattformen zur militärischen Aufklärung hat in der Geschichte der Luftfahrt und des Militärs eine lange Tradition und hat sich bis heute weiterentwickelt. Die ersten Schwarzweißfotos (links in Abb. 2): wurden nach dem Flug ausgewertet und lieferten wertvolle Informationen über Gefechtsstärke, Infrastruktur oder Geländegegebenheiten.



**Abb. 2:** Die Anfänge der Fernerkundung waren militärischen Ursprungs (links). Auf aktuell eingesetzten Fernerkundungsplattformen (rechts) werden unterschiedliche, meist lagestabilisierte Sensoren eingesetzt, beispielsweise: hochauflösende Farbkamera zur Eventüberwachung, thermische Kameras zur Grenzüberwachung oder Entfernungssensor zur Inspektion von Stromleitungen [Lind03, Ouas07].

Moderne Sensorsysteme haben das Einsatzspektrum von Fernerkundungs- und Aufklärungsplattformen deutlich erhöht [Esca13][Azaa07][Bald14]:

- Hochaufgelöste *photographische Aufnahmen* werden unter anderem zum Kartieren, für Überwachungsaufgaben am Tag, zur Übertragung von Veranstaltungen, Ereignissen und in der Stadtplanung eingesetzt [Lang13].
- Aus Temperatursignaturen lassen sich gezielt Rückschlüsse über Art, Zustand und Bewegung von Objekten und Lebewesen ziehen. Temperaturmessende *Wärmebildkameras* (LWIR) sind daher sehr verbreitet zur Überwachung in der Nacht (u.a. zur Grenzkontrolle, Wildüberwachung) oder bei der Inspektion (Überprüfung von Anlagen, Hochspannungsleitungen, Pipelines oder zum Finden von Energieverlusten) [KuDe13].
- Vegetationsarten und Untergründe (Gesteinsarten, Wasser, Rohstoffe etc.) treten in den verschiedenen Wellenlängen (Spektren) unterschiedlich stark hervor und werden somit klassifizierbar [ZhPi13]. *Multi- und Hyperspektrale Kameras* kommen daher in der Präzisionslandwirtschaft, im Umweltschutz, in der Metrologie, dem Straßenbau und in der Geologie zum Einsatz.
- *Entfernungsgebende Sensoren* (LIDAR, RADAR, SAR) eignen sich zum Erstellen von digitalen Höhenkarten und Geländemodellen, zur Vermessung von Städten oder archäologischen Stätten, zum Erfassen von Baufortschritten sowie zum Erkennen und Greifen von Objekten oder Hindernissen aus der Luft [KHSL14, Wang11].
- Sensoren zur Erfassung und Analyse elektronischer Signale (engl. *signals intelligence*, SIGINT) dienen i.d.R. zur Aufklärung und sind daher dem Militär und der Polizei vorbehalten [HRSS12].
- Anwendungsgetriebene „Exoten“ werden u.a. in Form „*elektronischer Nasen*“ zum Aufspüren atomarer, biologischer, chemischer Bedrohungen oder zur Erkennung und Lokalisierung von Brandherden eingesetzt [ChKu03].

Häufig wird eine Kompensation der Fluglage und möglicher Vibrationen<sup>2</sup> vorgesehen, um qualitative hochwertige Sensoraufnahmen zu erzielen. Die verbauten Sensoren sind hierzu mit Hilfe einer kardanischen Aufhängung um mehrere Achsen drehbar gelagert und können regelungstechnisch stabilisiert werden (engl. *gimbal*, rechts in Abb. 2). In Kombination mit steuerbaren Zoomobjektiven ist neben der Lagestabilisierung eine gezielte Ausrichtung und somit die Wahl des Blick-/Messfeldes (eng. *Field-of-View*, *FoV*) möglich.

Bei kleineren Fluggeräten sind die Kapazitäten der Nutzlast beschränkt. Die Einschränkungen betreffen u.a. Größe, Gewicht sowie Energiebedarf. Eine notwendige Vorauswahl der Sensorik und Optik orientiert sich an der zu erfüllenden Aufgabe und an den zu erwartenden Umgebungsfaktoren wie Tages- und Jahreszeit, Wetter oder Terrain sowie den genannten Einschränkungen. So finden sich in der Literatur (vgl. Aufzählung) unterschiedliche Auswahlkriterien und Bewertungen. Die folgenden Beispiele dienen nur exemplarisch zur Veranschaulichung des Sachverhalts:

- Tagsüber sind CMOS- und CCD-Kameras, die Farbbilder aufnehmen, eine gute Wahl zur Sensordatenerfassung und -auswertung. Jedoch ist ihr Einsatz bei Dämmerung oder in der Nacht aufgrund des begrenzten Lichts nicht oder nur sehr eingeschränkt möglich. Für die Nachtaufklärung werden bevorzugt temperaturmessende Sensoren eingesetzt,

---

<sup>2</sup> verursacht durch Motor/Rotor und/oder Wind

aber auch entfernungsmessende Sensoren kommen zum Einsatz. Beide Sensorarten können ohne Umgebungslicht arbeiten und liefern somit auch bei schlechten Lichtverhältnissen verlässliche Sensordaten [Klei04], [KaBl08].

- Über ebenem Terrain können Objekte und Personen aufgrund ihrer Höhendifferenz zum Hintergrund leicht erkannt werden. In Gegenden mit Gebirgen oder bewaldeten Flächen kann jedoch eine höhenbasierte Segmentierung mit Hilfe von Entfernungssensoren aufgrund des inhomogenen Terrains leicht zu Fehldetektionen führen [RVSO12, WRRG07a, WRRG07b].

### Experten für die Bild- und Sensordatenauswertung

Zur verlässlichen Analyse der gesammelten Daten müssen Bildauswerter gezielt auf die jeweilige Anwendung hin geschult werden [Esca13], [Löff85]<sup>3</sup>. Das Expertenwissen ist i.d.R. sensor- und domänenabhängig und wird u.a. in den folgenden Anwendungsgebieten benötigt:

- Professionelle Auswerter bei der Polizei und dem Militär liefern Ergebnisse hinsichtlich des Zustands, der Identität und des Verhaltens von Objekten und Personen (Abb. 3).
- Geologen, Biologen und Forstwirte ziehen fundierte Rückschlüsse auf die Art des Untergrundes, das Pflanzenwachstum oder den Schädlingsbefall [ZhPi13].
- Ingenieure werten u.a. thermische Aufnahmen zur Gebäudedämmung, zur Inspektion von Stromtrassen oder zur Analyse von Straßenbelägen aus [Vach15].



**Abb. 3:** Aufklärungseinsätze des AG51 in Afghanistan: links) Aufklärungstornado mit GAF-Teleleus Pod und Auswertestation für die Nassfilmaufnahmen, mittig) Aufrüstung des Aufklärungsbehälters (RecceLite 2009-2010) zur echtzeitnaher digitalen Videoübertragung, rechts) Unbemannte Einsätze mit Heron 1 UAS [Bund10].

<sup>3</sup> „Der Beobachter muss lernen, die Information, die das Luftbild vermittelt, mit Hilfe geeigneter Kriterien in die für ihn relevante Information umzusetzen. Derartige Kriterien sind z. B. Grau- oder Farbton des Bildes, seine Textur, Bildmuster, sowie bei stereoskopischer Betrachtung das dreidimensionale Bild der Oberflächenformen. Diese Kriterien können aber nicht „mechanisch“ angewendet werden, sondern der Interpret muss durch Erfahrung im Umgang mit Luftbildern aus den verschiedensten Gebieten lernen, sie sinnvoll umzusetzen.“ [Löff85]

Trotz intensiver Schulungen ist eine Luftbildinterpretation (Abb. 3) nicht immer zufriedenstellend oder eindeutig möglich [Löff85]<sup>4</sup>. Vor allem unter dynamischen Umweltbedingungen und bei Zeitmangel führt Stress zu Fehlinterpretationen [PiCD08].

Die Bildauswertung erfolgt aus Kostengründen zumeist noch nach dem Flug [Chen07, Lang13]. Jedoch ist bei der Aufklärung [Luft13]<sup>5</sup>, Verkehrsüberwachung, Grenz- und Katastrophenschutz sowie bei der Suche nach Personen oder Vermissten [Tapr11] eine kurze Latenzzeit zwischen Sichtung und Aktualisierung des Lagebildes häufig für den Erfolg der Mission entscheidend.

## 2.2 Unbemannte Flugsysteme

In diesem Abschnitt werden zunächst Grundlagen und Einsatzmöglichkeiten unbemannter Luftfahrzeuge vorgestellt. Es folgen Konzepte und Methoden zur Missionsplanung und -durchführung. Abschließend werden aktuelle UAS-Architekturen aufgeführt, die explizit eine Sensordatenverarbeitung als Teilsystem berücksichtigen.

### 2.2.1 Einsatz und Anwendungsbeispiele

Als UAS (engl. *Unmanned Aircraft System*) wird ein operationelles Gesamtsystem verstanden, das neben dem unbemannten Fluggerät (UAV) sämtliche Komponenten einschließt, die zur Führung, Überwachung und Wartung benötigt werden. Ein einsatzfähiges UAS benötigt demnach neben dem UAV eine aktiv wirkende oder messende Nutzlast und eine (Boden-) Kontrollstation samt Datenverbindung zur Flugsteuerung und Sensordatenübertragung sowie Möglichkeiten zur Missionsplanung und -überwachung.

Der Verzicht eine Besatzung ermöglicht bei unbemannten Luftfahrzeugen konstruktive Spielräume hinsichtlich Größe und Gewicht. Das eingesparte Gewicht ermöglicht eine höhere Nutzlastkapazität und längere Einsatzzeiten.



**Abb. 4:** UAV Beispiele: Global Hawk (HALE), Shadow 200 (TUAV), Aladin (Mini-UAV), Mikado (Micro-UAV), DHL-Paketcopter (VTOL-UAV) [Blom10, Rese14, Vach15]

Die Fluggeräte werden gezielt auf die Anwendung ausgelegt (Abb. 4). Sie unterscheiden sich neben Größe und Gewicht auch durch Startfähigkeit, maximale Flugleistung, mögliche Einsatzdauer und Art der Nutzlast. Lange Einsatzzeiten und hohe Nutzlasten sind großen Fluggeräten vorbehalten, wohingegen kleine Mini- und Micro UAVs häufig hand- oder

<sup>4</sup> „Die Luftbildinterpretation kann nicht immer eindeutige und von unterschiedlichen Bearbeitern exakt wiederholbare Ergebnisse liefern.“ [Löff85]

<sup>5</sup> „Kritisch ist dabei das Informationsalter, worunter die Zeit vom Moment des Überfluges – also der Aufnahme – bis zum Vorliegen der Einsatzergebnismeldung beim jeweiligen Auftraggeber verstanden wird.“ [Luft13]



senkrechtstartfähig sind. Daher kommen sie i.d.R. ohne zusätzliche Start- und Landevorrichtungen aus und lassen sich einfacher transportieren sowie in Betrieb nehmen. Aufgrund des verringerten Gewichtes, ihrer Größe, des Geräuschpegels und der niedrigeren Flughöhe sind kleine UAVs zudem weniger strengen Zulassungsaufgaben unterworfen [Hadd09]. Dies macht sie neben finanziellen Aspekten gerade für den zivilen Sektor lukrativ [CNSS06].

Die eigentliche Kontrolle und Entscheidungsgewalt obliegt den UAV-Operateuren in der Bodenkontrollstation (BKS). Wie in Abb. 5 rechts am Beispiel der Führung der KZO-Drohne gezeigt, beinhalten aktuelle Bodenkontrollstationen mehrere Arbeitsplätze zur Missionsplanung und -durchführung, zur Sensorauswertung und zur Kommunikation.



**Abb. 5:** Systemkomponenten eines UAS am Beispiel der KZO nach [WoBl07]: Fluggerät KZO UAV (links), Datenlink (mittig), Bodenkontrollstation (rechts) mit Flugführungs-, Sensor- und Kommunikationsarbeitsplatz.

BKS und UAV sind über einen oder mehrere Datenlinks miteinander verbunden. Häufig wird hierbei zwischen ausfallsicheren und weitreichenden Kontroll- sowie breitbandigen Sensorfunkstrecken unterschieden. Die Führung des Fluggerätes geschieht entweder reinmanuell durch direkte Steuerkommandos, auf Wegpunktbasis oder hoch automatisiert z.B. in Form von Aufträgen und Aufgaben [ChWL09, GoKM09, Kend12]. Hierfür notwendige regeltechnische Systeme zur Lagestabilisierung (engl. *Flight Control System*, FCS) und zur Navigation (engl. *Flight Management System*, FMS) sind ebenfalls auf dem UAV integriert.

Je nach Anwendungszweck werden unterschiedliche Nutzlasten integriert. Zu den wirkenden Nutzlasten zählen Manipulatoren (Logistik- und Transportsysteme) sowie Waffensysteme. Kommunikationssysteme und klassische messenden Missionssensoren gliedern sich dagegen in die nicht-wirkenden Nutzlasten ein [MKBO10]. Die Anwendungsgebiete decken sich einerseits mit Anwendungen luftgestützter Fernerkundungsplattformen (Abschnitt 2.1). Andererseits erschließen UAVs neue Geschäftsfelder und Applikationen [GuGJ13, Skrz11], die aufgrund der hohen Anschaffungs- oder Unterhaltskosten bemannter Plattformen betriebswirtschaftlich unrentabel oder aufgrund der Größe, der Einsatzdauer oder des Lärms bemannter Plattformen operationell nicht abdeckbar wären.

Der Einsatz unbemannter Plattformen<sup>6</sup> hat sich dabei vor allem in den sogenannten „*dull-dirty-dangerous*“ Missionen bewährt [Depa07, Depa13]:

<sup>6</sup> UxS (engl. *Unmanned Systems*) u.a. UAS und UGS (engl. *Unmanned Ground System*)

- Als „*dull*“ werden langwierige Einsätze charakterisiert. Hierzu zählen beispielsweise mehrtätige Befliegungen großflächiger Gebiete (Aufklärungsflüge, Grenzkontrollen, Umwelt- und Gewässerschutz) oder die Inspektion langer Transportleitungen (Öl-, Gaspipelines, Stromtrassen) [Aust09]. Diese Einsätze werden ermöglicht, da die Operateure in der BKS im Schichtbetrieb ohne Zwischenstopps getauscht werden.
- Als „*dirty*“ werden Missionen bezeichnet, in denen mit gesundheitlichen Folgeschäden aufgrund toxischer oder radioaktiver Substanzen zu rechnen ist. So wurden UAVs zur Waldbrandbekämpfung [MCMF06], im Katastrophenschutz z.B. bei der Überwachung des Reaktorbrandes in Fukushima oder zum Ausbringen von Pflanzenschutzmitteln [ZhPi13] eingesetzt.
- Als „*dangerous*“ lassen sich Missionen klassifizieren, bei denen mit dem Verlust des Fluggerätes und der Besatzung zu rechnen wäre. So haben sich UAVs beispielsweise bei der Aufklärung über feindlichem Gebiet; während des Einsatzes als Zieldarstellung aber auch bei der Überwachung aktiver Vulkane oder zur Prüfung der Lawinenlage im Gebirge [Niet13] bewährt.

Neben diesen operationellen Vorteilen bietet sich der Einsatz von UAVs auch aus *betriebswirtschaftlichen Gründen* an [Depa13, Tapr11, Weze07]. Die Einsparungen betreffen personelle und logistische Unterhaltskosten aber auch die Anschaffungskosten [Aust09]. Der Trend hin zu unbemannten Systemen wird sich nach amerikanischen Quellen noch weiter verstärken [Depa07, Depa13]. Die Perspektiven des europäischen [Weze07] sowie deutschen Marktes verlaufen tendenziell ähnlich positiv, wobei im Vergleich zu den USA oder Israel ein gewisser Nachholbedarf feststellbar ist [Tapr11].

Potentielle Anwendungsgebiete von UAVs können nach [CNSS06, GuGJ13, Tapr11] in zwei unterschiedliche Kategorien eingeteilt werden:

- Hoheitliche Aufgaben [Esca13, Weng10]:
  - Aufklärung und Durchführung militärischer Missionen
  - Verkehrs-, Küsten- & Seeüberwachung, Bergwacht, Grenz- und Objektschutz
  - Überwachung von Ökosystemen (Wald, Gewässer), Klimamonitoring
  - Notfall- und Rettungseinsätze sowie Verkehrsüberwachung, Katastrophenschutz
  - Kommunikation (u.a. als Relaisstationen)
- Privatwirtschaftliche Verwendungen [GöSu14, RLHW09, ToHo13, ZhPi13]:
  - Bild- und Videoaufnahmen (Nachrichten, Unterhaltung, Werbung)
  - Inspektion von Großanlagen, Stromleitungen, Pipelines, Werkschutz
  - Agrarwirtschaft, Tierhaltung und Fischerei
  - Kartographie, Geologie sowie Geoinformatik
  - Wettervorhersagen
  - Kommunikation
  - Lasten- und Personentransport



Für künftige zivile Anwendungen werden insbesondere kleine und mittlere UAVs eine immer wichtigere Rolle spielen [Hadd09, Tapr11, Vach15, Weze07]. Neben Vorteilen eines bodennahen Einsatzes liegen die Gründe in der Zulassungsproblematik [Hutc07, Jeni13], der Kostenstruktur, dem Wartungsaufwand und der Komplexität großer UAS [BrAL11, EGKP18]. Allerdings sind kleine UAVs hinsichtlich ihrer möglichen Nutzlast in Gewicht, Größe und Energieverbrauchs limitiert. Dies schränkt die Auswahl der Sensoren, die Reichweite, die Qualität des Datenlinks (Sendeleistung, Antennen) sowie die Kapazität der Missionsrechner und somit letztlich das Einsatzspektrum und den Nutzen ein.

### 2.2.2 Missionsplanung und -durchführung

Die Funktionalität aktueller Missionsmanagementsystem (MMS) umfasst nicht nur die Unterstützung zur statischen Missionsplanung vor dem Flug. Vielmehr sollen sie den Operateur auch während des Fluges beim Führen des Fluggerätes und beim Einsatz der Nutzlast aktiv unterstützen, damit vorgegebene Ziele und Vorgaben erfüllt und eingehalten werden können.

Dennoch stoßen menschliche Bediener gerade in komplexen Situationen und in dynamischen Umgebungen an ihre Belastungs- und Beanspruchungsgrenzen [Dona11, Kend12, MuSh12]:

- Beim gleichzeitigen Verfolgen mehrerer Ziele mit unterschiedlichen Prioritäten, zeitlichen, örtlichen Randbedingungen und unter beschränkten Ressourcen müssen Abwägungen getroffen werden, in welcher Reihenfolge, wie, wann und ob überhaupt ein Teil oder alle Ziele erreichbar sind.
- Im Laufe einer Mission können sich sowohl die übergeordneten Ziele ändern als auch neue Objekte und Hindernisse auftauchen<sup>7</sup>. Eine erforderliche Analyse und Bewertung der Situation im Sinne des Missionskontexts kann eine Um-/Neuplanung der bisherigen Flugroute sowie eine Neuausrichtung der Nutzlast nach sich ziehen (Abb. 6).
- Um den Einsatz der UAV-Führung zu optimieren, müssen neben den primären Zielen auch zusätzliche Randbedingungen und unvorhersehbare Systemzustände, wie die Integration in den Flugraum, Einsatzregeln (engl. *rules of engagement*, ROE) Kraftstoffverbrauch oder ein möglicher Ausfall von Teilsystemen (engl. *health and status monitoring*) berücksichtigt werden.
- Die Koordination gleicher oder unterschiedlicher UAVs (Multi-UAV) bietet neue Möglichkeiten. Allerdings steigt mit der Anzahl der UAVs auch die Systemkomplexität und damit die Beanspruchung und Belastung der Operateure [Meit08, Uhrm12]. Die Koordination, Routenplanung und Optimierung mehrerer UAVs ist unter realen Einsatzbedingungen ohne höherwertige Assistenzsysteme nicht mehr durchführbar [OlMa07].

Um diesen Herausforderungen gerecht zu werden, könnte der menschliche Entscheidungsprozess im Computer nachempfunden und modelliert werden. Diese Ansätze finden sich in *kognitiven Missionsmanagementsystemen* wieder. Sie sollen langfristig einen

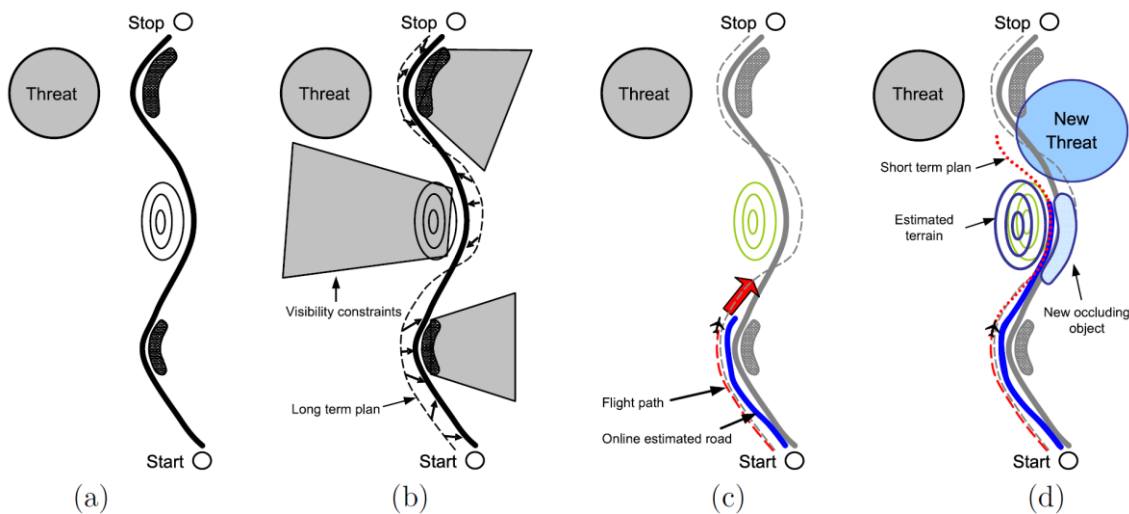
---

<sup>7</sup> „Some situations may call for strategic planning to handle new or unanticipated science goals. One way this can happen is if the UAV receives a new goal from an operator or another UAV. This can also happen if unexpected, interesting features are found in the sensor data. In the case of novel features, the UAV must consider whether the new feature constitutes a new goal. In either case, the UAV now has to revise its plan to account for the new goals as well as the previous goals.“ [STWE04]

Grad der Autonomie erreichen, der die selbständige Abarbeitung von Aufträgen ohne Zutun des Operateurs ermöglicht [BiRo07, BrSc12, ChWL09, Meit08, UhSc12]. Dies würde die Operateure von Routine- und Optimierungstätigkeiten entlasten, wodurch sie sich höherwertigen Aufgaben im Rahmen der Missionserfüllung widmen zu könnten [Raus13].

Methoden und Konzepte zur Situationsanalyse, der Planung, Aus- und Durchführung, sowie zur UAV-Koordination [Kend12, NSKB05, Vach15] stammen aus einem breiten Spektrum wissenschaftlicher Disziplinen. Dazu zählen unter anderem die Entscheidungs- und Spieltheorie als Teilgebiet der künstlichen Intelligenz [RuNo20], die Optimierung (engl. *operations research*, [Hill14]) und die Kognitionswissenschaft, die sich mit dem Ziel beschäftigt, menschliche Denk- und Verhaltensprozesse sowie Interaktionsmöglichkeiten zwischen künstlicher und menschlicher Intelligenz zu erforschen [BiRo07, OnSc10].

Das Finden einer globalen Lösung für kombinierte Pfad-Sensor-Planungsaufgaben ist in hochdimensionalen Problem- und Zustandsräumen aufgrund limitierter Ressourcen häufig nicht in echtzeitnahe möglich. In dynamischen Umgebungen ist dies jedoch auch nicht zwangsläufig ratsam. So führen manuell oder automatisch erkannte Objekte, Hindernisse oder Verdeckungen zu einer Neubewertung/Interpretation der Lage/Situation und damit auch zu einer Neuplanung der Handlungsalternativen. Vielmehr bietet sich in dynamischen Umgebungen eine Zerlegung des Planungshorizont anhand zeitlich-örtlicher Kriterien an. In Abb. 6 ist hierzu ein prototypisches Verkehrsüberwachungsszenario nach [NSKB05] dargestellt, an dem sich die unterschiedlichen zeitlichen Planungshorizonte erörtern lassen:



**Abb. 6:** Pfad- und Sensorplanungssystemen Beispiel (road surveillance scenario, [NSKB05]):

(a) Ausgangslage (prior information). (b) Ursprünglicher Plan (initial plan). (c) Überwachung und Simulation (probing). (d) Aktualisierung, Neuplanung aufgrund einer neuen Situation oder veränderter Umgebungsparameter (replanning)

- Die *Langzeit-Pfadplanung* (engl. *Long-term Platform path planning*, LP) berücksichtigt die Ausgangslage, bekannte Bedrohungen und Einschränkungen, angefragte Überwachungsaufgaben und zeitlich-örtliche Grenzen. Hieraus kann ein initialer Pfad zur Führung des UAVs berechnet werden.
- Die *Kurzfristige Plattform-Pfadplanung und Langfristige Sensorplanung* (engl. *Short-term Platform path planning and Long-term Sensor planning*, SP-LS) greift einerseits

auf die Langzeit-Pfadplanung (LP) zurück und konsolidiert diese zur Bahnglättung, aufgrund neu erkannter Bedrohungen und Objekten, zur Sichtbarkeitsoptimierung, zur Hindernisvermeidung und zum Bearbeiten neuer Aufklärungsaufgaben. Darüber hinaus wird ein erster Langzeit-Sensoreinsatzplan erstellt.

- Die *Reaktive Plattform-Pfadplanung und Kurzfristige Sensorplanung* (engl. *Reactive Platform path planning and Short-term Sensor planning*, RP-SS) greift auf SP-LS zurück. Sie dient zur Hindernisvermeidung und soll zudem die Sichtbarkeit erhöhen und gleichzeitig helfen Verdeckungen zu vermeiden. Dies kann aus dem Zusammenspiel zwischen reaktiver Anpassung von Position und Lage sowie geplanter Blickwinkelsteuerung realisiert werden.
- *Reaktive Sensorplanung* (engl. *Reactive Sensor planning*, RS) dient der Optimierung der Sensorparameter (Focus, Zoom, Kontrast) sowie der Anpassung der Blickwinkelsteuerung.

### 2.2.3 Ausgewählte Systemarchitekturen

Umfassende Recherchen zu UAS-Architekturen finden sich in [Ange12, ChWL09, GoKM09, Kend12, Vach15]. Systeme, die eine sensor-orientierte Missionsplanung berücksichtigen, lassen sich in drei Kategorien unterteilen:

- a) *Reaktive* Systeme sind durch eine direkte Auswertung der Sensorverarbeitung zur Flugführung gekennzeichnet. Derartige Systeme werden zur visuellen Navigation wie dem Verfolgen von Fahrzeugen oder Abfliegen einer Straße [BPIC12, MTFP11, TRZX06], zur Hindernisvermeidung [BPHR11, HMTF11, RBAG10, WaCJ07] oder zur automatischen Landung [MFEX09, ScCS10, ScCS12, ThRA06, WTSG09] verwendet. Die Funktionsweise kann an der Systemarchitektur von [BPIC12] in Abb. 7 erklärt werden. Aus den Sensordaten werden zunächst relevante Objekte (z.B. Hindernisse, Fahrzeuge, Straßen) extrahiert oder eine Hinderniskarte (engl. *obstacle map*) erstellt. Objektpositionen und die Hinderniskarte können anschließend direkt von Flugführung in Sollgrößen für die unterlagerten Regelkreise umgesetzt werden.

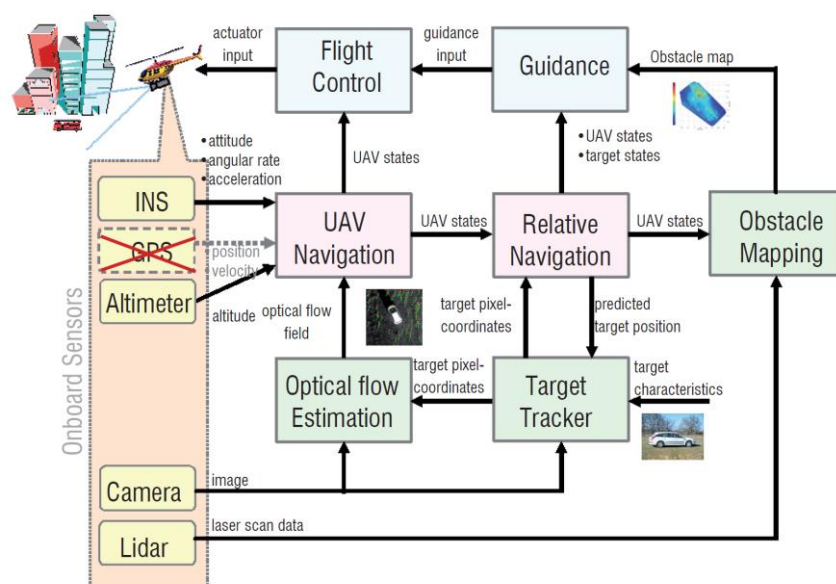


Abb. 7: Systemarchitektur zur sensorbasierten Flugführung nach [BPIC12]

b) *Deliberatives* und zielorientiertes Verhalten lässt sich realisieren, indem höherwertigere Perzeptionsergebnisse wie die Klassifikation oder Identifikation von Objekten in Form semantischer Objekte in eine Situationsbeschreibung und -bewertung integriert werden (engl. *situation evaluation/assessment* in Abb. 8). Je nach Art, Lage und Zeit kann sich durch ein wahrgenommenes Ereignis eine neue Situation ergeben. Gerade unvorhergesehene Ereignisse, unbekannte Entitäten (Personen, Fahrzeuge), Hindernisse oder Bedrohungen führen zu einer Neu-Bewertung der aktuellen Situation. Eine Verletzung von zu erfüllenden Randbedingungen oder eine Änderung hinterlegter Ziele führt letztlich zu einer Neu- oder Umplanung der bisherigen Mission.

Eine Gemeinsamkeit deliberativer Systeme ist die hierarchische Struktur [Kend12] beginnend mit der Wahrnehmung relevanter Objekte, der Situationsanalyse und Überwachung und einer Entscheidungs-/Planungsinstanz.

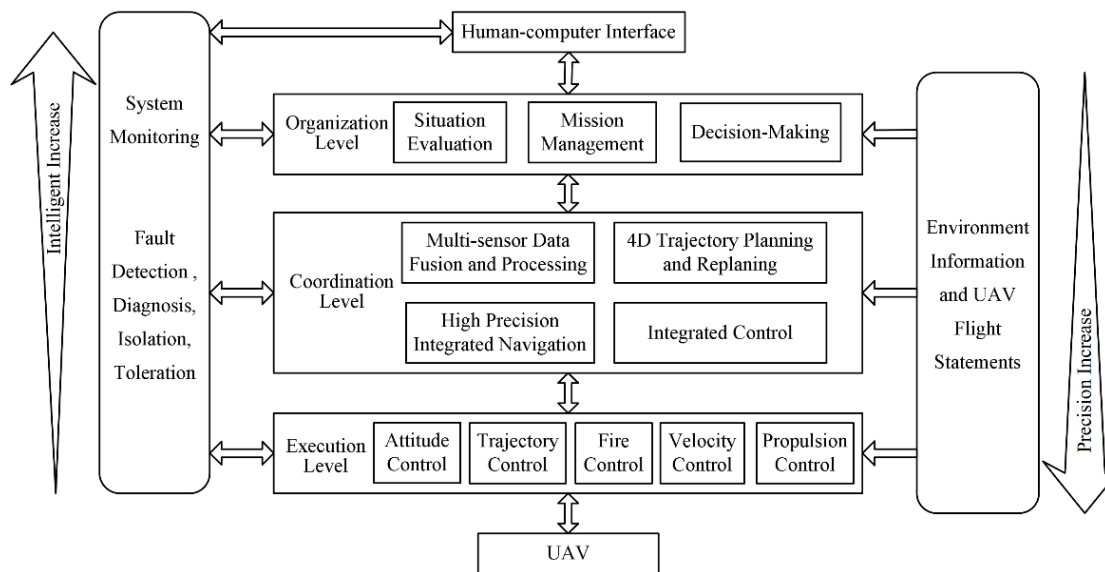


Abb. 8: Hierarchische Architektur zur autonomen UAV Führung [ChWL09]

c) *Hybride* Systeme [DKWR14, Krog03, Vach15] nutzen sowohl symbolische Ergebnisse für ein zielorientiertes Verhalten (deliberativer Teil) und ermöglichen andererseits schnelle Reaktionszeiten durch eine direkte Kopplung zwischen Sensorauswertung und Flugführung (reaktiver Teil).

Als Vertreter hybrider Systeme ist die HDRC3 Architektur [DKWR14] Abb. 9 dargestellt. HDRC3 ist eine sehr umfassende Architektur und ging aus dem WITAS Projekt zur Verkehrsüberwachung hervor [DGKS00]. Planungsalgorithmen dienen zur Pfadplanung und Aufgabenverteilung. Die Koordination der reaktiven Ebene wurde mit Hilfe von hierarchischer Zustandsautomaten realisiert. Auf der hierarchisch höher angeordneten Aufgabenebene werden sogenannte „*Task Specification Trees*“ zur Entscheidungsfindung eingesetzt. Neben einer abstrakten Beschreibung der Flugführungsaufgaben werden hierbei Sensor-/Wahrnehmungsfähigkeiten explizit mit Hilfe einer Ontologischen Beschreibungssprache (*DyKnow*) modelliert. Allerdings wurde damit bisher nur ein statisches Fähigkeitsmanagement realisiert, konkrete Verbesserungsvorschläge oder eine situationsgerechte Neubewertung der Fähigkeiten wurden bisher nicht umgesetzt [DKWR14].

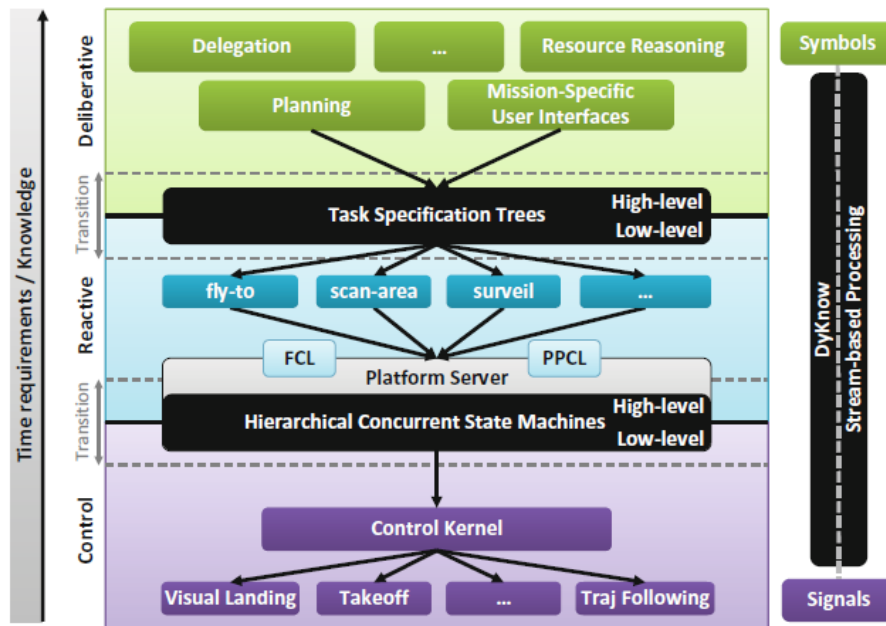


Abb. 9: Hybride UAS Architektur HDRC3 [DKWR14]

Als Erweiterung zielorientierter Systeme können *fähigkeitsbasierte Architekturen* [HSRS12, Pell03, RuSt12] bzw. *serviceorientierte Architekturen* ([FIBr13, MAJL13, RCBS13, RLPB08, RMEM11]) aufgefasst werden. Sie umfassen die oben erwähnte hierarchische Struktur und nutzen zusätzlich eine explizite Beschreibung einzelner Fähigkeiten bzw. Services.

Wie in Abb. 10 dargestellt, kann hierbei zwischen Flugführungsfähigkeiten, Missionsfähigkeiten und Nutzlastfähigkeiten unterschieden werden. Letztere sollten nach [RuSt13a] neben Sensor- und Waffeneinsatz gerade auch verarbeitende Wahrnehmungsfähigkeiten einschließen. Die Fähigkeiten können sich während des Fluges ändern: aufgrund interner Systemzustände<sup>8</sup> oder durch externe Zustandsänderungen (neue Missionsziele und Randbedingungen, geänderte Umwelteinflüsse). Sie sind also nicht statisch, sondern sollen jeweils den aktuellen Fähigkeitsumfang des Systems widerspiegeln.

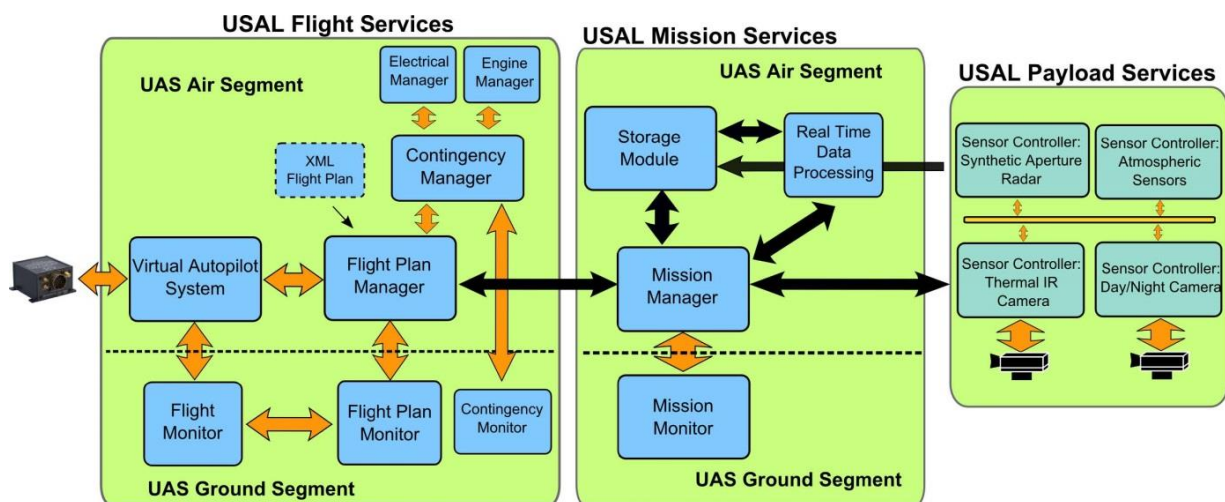


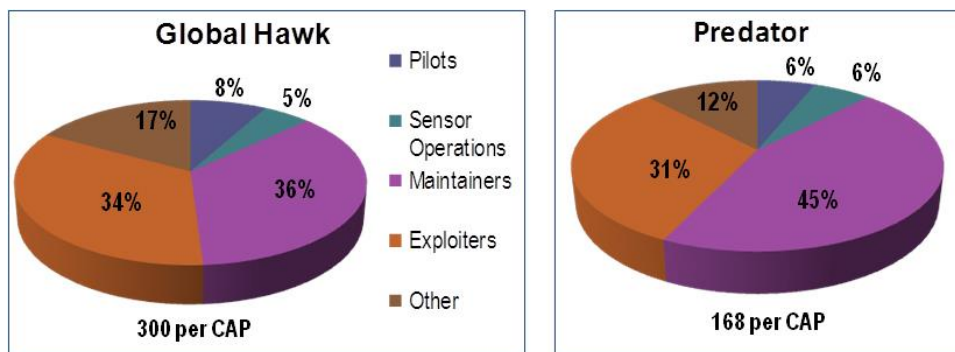
Abb. 10: Service orientierte UAS Architektur nach [RCBS13] (engl. *UAS Service Abstraction Layer, USAL*).

<sup>8</sup> „Contingency Manager“ in Abb. 10 überwacht hierzu die Leistungsfähigkeit und den Ausfall der Subsysteme.



### 2.3 Herausforderungen künftiger Anwendungen

Der Einsatz moderner UAS hat sich u.a. in militärischen Missionen und für Überwachungs- sowie Inspektionsaufgaben als erfolgreich und unverzichtbar herausgestellt. Flächendeckende Einsätze in Afghanistan und im Irak haben jedoch auch zur Erkenntnis geführt, dass UAVs eine Fülle an Sensordaten liefern können, die von menschlichen Bildauswertern nicht mehr kosten- und/oder zeiteffizient handzuhaben sind [MuSh12]<sup>9</sup>. So sind bis zu 40% des UAS-Personals mit dem Einsatz und dem Auswerten der Sensorik beschäftigt (siehe Abb. 11).



**Abb. 11:** Personalbedarf für den Einsatz großer UAS nach [Mayb11, MuSh12] führt zu Engpässen und Kostenproblemen: „Our #1 manning problem in the Air Force is manning our unmanned platforms” [Mayb11].

Gerade hochauflösende und multispektrale Sensoren führen bei Langzeit- oder flächendeckenden Befliegungen zu enormen Datenmengen und somit so langen Übermittlungs- und Auswertezeiten. In Anlehnung an den militärischen Aufklärungszyklus bieten sich zwei Möglichkeiten zur Optimierung an [Nort05]:

- Eine *Übermittlung der Missionssensordaten während des Fluges* an die Bodenauswertungsstation kann erste Eindrücke in nahezu Echtzeit (mittig in Abb. 3) liefern. Gleichzeitig könnte unmittelbar nach der Aufnahme, also noch während des Flugs mit einer (Teil-)Auswertung begonnen werden. Dies setzt jedoch eine stabile und breitbandige Datenverbindung zwischen Auswertestation und Fluggerät voraus.
- Ein effizienter Ausweg wäre eine *computergestützte, automatisierte Wahrnehmung* der Umwelt, die neben missionsbezogenen und aufgabenspezifischen Auswertergebnissen auch zu navigatorischen, manipulatorischen oder logistischen Aufgaben während des Fluges genutzt werden könnte.

Die Integration von Bildverarbeitungsroutinen wäre sowohl in der Bodenkontrollstation oder direkt auf den Missionsrechnern des UAVs möglich. Eine Auswertung direkt auf dem Fluggerät wäre hierbei aus den folgenden Gründen erstrebenswert:

<sup>9</sup> “Time delays accrue from the need to have human analysts interpret data and the volume of data that has to be transmitted over networks for offboard processing. This manpower allocation and accrued latency could be reduced by onboard sensing algorithms that perform recognition of key objects or conditions, filter or prioritize data and adapt the distribution of data to network availability ... Current unmanned systems are designed to perform manned operational functions off-board over a communication link, which often results in cumbersome operator control systems, brittle operations and less robust capability than could otherwise be achieved with onboard processing.” [MuSh12]

- Eine Auswertung auf dem Fluggerät wäre auch bei schlechter Qualität der Datenverbindung<sup>10</sup> möglich.
- Gezieltes Stören oder Abhören der Datenverbindung hätte nur einen geringen Einfluss auf die erfolgreiche Missionsdurchführung.
- Verzögerung durch die Übertragung der Sensordaten in die Bodenk Kontrollstation entfallen teilweise oder ganz.
- Eine vollautomatische Sensorauswertung auf dem Fluggerät zur Erkennung von Missionszielen sowie eine automatisierte sensorgestützte Flugführung könnte den Grad der Autonomie spürbar erhöhen. Dies würde die Einsatzmöglichkeiten von (autonomen) UAVs einerseits erweitern und gleichzeitig die Belastung und Beanspruchung der UAV-Operateure bzw. Bildauswerter reduzieren, wodurch eine Konzentration auf missionskritische Aufgaben erleichtert würde.

Der Trend in Richtung MUM-T (engl. *Manned-Unmanned Teaming*) und Multi-UAV bzw. Schwarm-Einsätzen [Depa13] erfordert einen höheren Automatisierungsgrad und somit auch eine Echtzeit-Sensordatenauswertung an Bord [MuSh12].

So vielversprechend die Perspektiven und Möglichkeiten einer automatisierten Sensorauswertung auch sein mögen, so schwierig gestaltet sich bisher deren einsatztaugliche Integration auf fliegenden Plattformen:

- UAVs sollen rund um die Uhr auch unter schwierigen und variierenden Umweltbedingungen einsetzbar sein. Der Betrieb sollte daher unabhängig von Wetter, Klima, Tageszeit und Geländebedingungen möglich sein [Tapr11]. Dies stellt nicht nur Herausforderungen an das Fluggerät (u.a. Wind oder Regen) sondern gerade auch an die Qualität der Sensordaten.
- Die Einschränkungen einer möglichen Nutzlast bezüglich Gewicht, Größe und Energieverbrauch limitieren vor allem bei kleinen UAVs die Auswahl der Sensoren, die Reichweite und Bandbreite des Datenlinks (Sendeleistung, Antennen) sowie die Leistungsfähigkeit der Missionsrechner.
- Die Zuverlässigkeit des Sensoreinsatzes sowie der Bildauswertung sollte den Fähigkeiten eines Bildauswerter entsprechen und damit menschliches Auswerten oder Eingreifen – ganz, teilweise oder zeitweise – überflüssig machen [RuSt12].
- Um (teil-)/vollautonome Einsätze zu ermöglichen, muss ein verzahntes Ineinandergreifen zwischen Flugführung und Missionsmanagement einerseits sowie Sensoreinsatz und Sensordatenauswertung andererseits ermöglicht werden.

Diese Erkenntnisse werden in dem folgenden Kapitel 3 am Stand der Technik vertieft, um in Kapitel 4 zu einer konkretisierten Aufgabenstellung für das Systemdesign zu gelangen.

---

<sup>10</sup> Eine unzureichende Verfügbarkeit der Datenverbindung kann beispielsweise bei fehlender Sichtverbindung, im Gebirge, Wald oder durch gezielte Störung (engl. *jamming*) des Datenlinks auftreten.





### 3. Stand der Technik

Das Kapitel führt zunächst in die Domäne Sensoreinsatzplanung und Sensormanagement ein (Abschnitt 3.1). Dabei soll ein Grundverständnis zur Sensor- und Informationsfusion, dem Sensormanagement, Ressourcenmanagement und Perzeptionsmanagement vermittelt und Terminologien präzisiert und definiert werden (vgl. Abb. 12). Darauffolgend werden aktuelle Modelle und Architekturen aus dieser Domäne vorgestellt, mit deren Hilfe der Sensoreinsatz optimiert werden könnte. Im Anschluss daran werden die Methoden und Möglichkeiten der maschinellen Sensordatenverarbeitung aufgezeigt (Abschnitt 3.2).

Das Kapitel schließt mit einer Zusammenfassung, wobei die Möglichkeiten, Herausforderungen und Anforderungen abgeleitet werden, die ein gezielter Sensoreinsatz sowie gesteuerte, automatisierte Sensordatenauswertung mit sich bringen. Dies dient der Konkretisierung der Problem- und Zielstellung im anschließenden Kapitel 4.

#### 3.1 Sensoreinsatzplanung und Sensormanagement

*„Mit **Informationsfusion** wird der Prozess bezeichnet, Daten aus unterschiedlichen Sensoren oder Informationsquellen mit dem Ziel zu verknüpfen, neues oder präziseres Wissen über physikalische Größen, Ereignisse und Situationen zu gewinnen. Informationen können dabei sowohl Rohsignale von Sensoren als auch verbal beschriebene Eigenschaften von Objekten sein. Auf Sensoren als Informationsquellen übertragen, soll durch Kombination zweier Sensoren  $S_1$  und  $S_2$  mit unterschiedlichen Wirkprinzipien die Leistungsfähigkeit  $L(S_1 \cup S_2)$  des Multisensorsystems so erhöht werden, dass  $L(S_1 \cup S_2) > L(S_1) + L(S_2)$  oder zumindest  $L(S_1 \cup S_2) > \max\{L(S_1), L(S_2)\}$  beträgt.“ [BePS06]*

Die **Leistungsfähigkeit** (engl. *sensor performance*) eines Sensorsystems umfasst nach [Mitt05]: Genauigkeit, Reproduzierbarkeit, Linearität, Sensitivität, Auflösung, Zuverlässigkeit, Reichweite und Messbereich bzw. Einsatzraum.

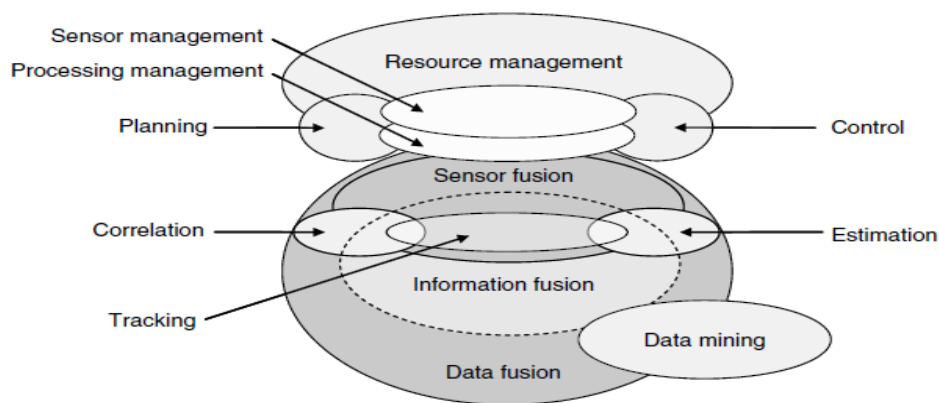
Sensorfusion im weiteren Sinne kann neben der eigentlichen Sensor- und Ergebnisverbesserung zudem den Prozess der Informationsgewinnung, der gezielten Sensorwahl (Zielorientierung, Entscheidungsfindung) sowie eine Bewertung von Einzelergebnissen einschließen [Raol09].

Weitere Definition finden sich u.a. in [Hal197, LiHL08, LuKa89, LuKa90, NgNg00]. Dabei wird vielfach zwischen den folgenden Prozessen unterschieden:

- **Integration** bezeichnet die „*synergetische Verwendung der Information mehrerer Sensoren zur Lösung einer Detektions-, Klassifikations- oder Identifikationsaufgabe*“ [LuKa89].
- **Datenfusion** umfasst die Methoden zur Kombination der Daten – Zeit- oder Ortssignale, Parameter, Aussagen. Es schließt u.a. Aufgaben der Korrelation, der Zustandsschätzung und des Trackings ein (vgl. Abb. 12).

Zur Ablaufsteuerung und Optimierung obiger Prozesse hat sich der Begriff des sogenannten **Sensormanagements**<sup>11</sup> etabliert. Ein im deutschen Sprachgebrauch verwendetes Äquivalent für Sensormanagement ist die sogenannte Sensoreinsatzplanung und -steuerung [BePS06, HGPB10, Hube09a, Knol99]:

*„Die Aufgabe der Sensoreinsatzplanung besteht in der Aktivierung von Sensoren und in der Einstellung ihrer Parameter mit dem Ziel der Lösung einer Erkennungsaufgabe bei Erreichung vorgeschriebener Erkennungsqualität und ggf. einer Obergrenze für entstehende Kosten. Solche Parameter sind der Sensorstandort bzw. der Sichtwinkel (bei bewegbaren bzw. mitbewegten Sensoren), die Empfindlichkeit und der fokussierte Bereich (Festlegung einer region-of-interest). Es geht hier darum, diese Parameter in der Wechselwirkung zwischen Erkennungsaufgabe, Objektstruktur und Sensorcharakteristik möglichst weitgehend automatisch zu bestimmen und dementsprechend einen Plan zu generieren, wann und wo welcher Sensor mit welchen Parametern zu aktivieren ist. Eine solche Planung ist die Voraussetzung für eine sinnvolle Fusion der redundanten Informationen aus den einzelnen Sensoren.“ [Knol99]*



**Abb. 12:** Schematische Darstellung zur Einordnung der Begriffe (Confusion of terminology nach [LILH08]).

Zusammenfassend kann festgehalten werden, dass das Sensormanagement folgende Fragestellungen einschließt [NgNg00, XiSv02]:

- Welche Wahrnehmungsaufgaben sollen durchgeführt werden und sind die Aufgaben priorisiert?
- Welcher Satz an Sensoren eignet sich grundsätzlich zur Erfüllung der Aufgabe?
- Welche Aktionen oder Anpassungen sind für die jeweiligen Sensoren zu treffen, um eine Verbesserung der Qualität zu erreichen?
- Wie sind hierfür die einzelnen Sensoren zu konfigurieren?
- Wann, wo und wie sollen die Sensoren eingesetzt werden?

Sowohl bei der Ausrichtung als auch bei der Konfiguration der Sensoren müssen vorgegebene Ziele und Anforderungen<sup>12</sup> eingehalten werden [XiSv02]. Hierbei können sich Ziele

<sup>11</sup> “Sensor Management is a process which seeks to manage or coordinate the use of sensing resources in a manner that improves the process of data fusion and ultimately that of perception, synergistically”. [MaDu95]

<sup>12</sup> “Inherently the purpose of sensor management is to optimize the data fusion performance by feedback control of sensor resources.” [XiSv02]


widersprechen oder nur zu einem Teil eingehalten werden. Eine Lösungsansatz besteht in der Vorausberechnung, Bewertung und Priorisierung geeigneter Strategien und Alternativen<sup>13</sup> [BeIr07].

Die Berücksichtigung der Trägerplattform und die Ableitung von Sensor-Plattform Fähigkeiten erweitern das Sensormanagement und führen zum Begriff des **Ressourcenmanagements** [BSD13, PrGo08, ScFG06]. Diese Ebene stellt den hierarchisch höchsten Abstraktionsgrad in Abb. 12 dar. Auf dieser Ebene sollen Multi-UxS Verbände oder Schwärme sowie Teams aus bemannten und unbemannten Systemen (MUM-T) missionsoptimal zusammengestellt und koordiniert werden [GPJM08].

Das in Abb. 12 als verarbeitende Zwischenebene dargestellte *Processing Management* dient hierbei einerseits zur Steuerung und Anpassung der sensornahen Vorverarbeitung und Merkmalsgewinnung sowie zur Objekterkennung und Zustandsschätzung andererseits. Um zu einer Präzisierung des Begriffes zu gelangen, wird das *Processing Management* im Folgenden als **Perzeptionsmanagement** (engl. *Perception Management*) [JoXi03, RuSt13b] bezeichnet.

### 3.1.1 Prinzipien und Methoden

Mit Hilfe von Venn-Diagrammen (Abb. 13) lassen sich mögliche Sensoreinsatzräume (engl. *detection space* oder *classification space*) gut veranschaulichen [Klei04].



**Abb. 13:** Venn-Diagramm für den Einsatz eines Multi-Sensor-Systems [Klei04].

Bildlich gesehen deckt jeder Sensor (A, B, C) einen bestimmten Bereich ab, indem er das zu messende Objekt abbilden kann. Je nach Einstellung des Sensors kann der Arbeitsbereich für bestimmte Situationen optimiert werden. Grundlegende Eigenschaften basieren auf den Sensormessprinzipien und lassen sich somit nicht verändern. So können bildgebende Kameras (CMOS, CCD) zwar mit lichtstarken Objektiven ausgestattet werden, am Grundprinzip dieser passiven Sensoren, also dem notwendigen Vorhandensein einer Lichtquelle, ändert dies jedoch nichts. Die Sensoreinsatzräume in den Venn-Diagrammen lassen sich folglich innerhalb gewisser Grenzen jedoch nicht beliebig verschieben. Ebenso sollte hierbei erwähnt werden,

<sup>13</sup> “Because the sensors cannot always meet all of the sensing requirements, the management system must decide which priorities to meet and which resources to allocate to that priorities. These decisions are influenced by the high-level analysis of the situation and generally balance the long-term objectives with immediate concerns. In this sense, sensor management boils down to choosing between a number of sensing strategies based on the conditions of the moment. Typically, the problem of selecting a strategy only arises when the situation changes in some fundamental way, such as when a new target enters or leaves”. [BeIr07]

dass die Leistung in der Regel abnimmt, wenn man sich den Randbereichen und somit den spezifischen Einsatzgrenzen des Sensors nähert.

Grundlegende Vorteile und Besonderheiten von Multisensor-Lösungen lassen sich ebenfalls anhand des Venn-Diagramms (Abb. 13) erklären.

- Die *parallele Auswertung* der Sensoren erlaubt es, Objekte auch dann zu erkennen, wenn Sie mit einem Sensortypen allein nicht erfassbar wären. Hierdurch kann ein *erweiterter, gemeinsamer Einsatzraum* aufgespannt werden, was einer Vereinigung der Mengen entspricht. Dies hat gleichzeitig aber auch einen erhöhten Rechenzeitbedarf und eine potenzielle Erhöhung der Fehlalarmrate zur Folge. Daher besteht in multi-Sensor Systemen der Wunsch ungeeignete Sensoren im Vorfeld bereits auszuschließen. Dieser Auswahlprozess (engl. *sensor selection*) wird auch als *cuing* oder *guiding* bezeichnet (Abb. 15) und beruht auf hinterlegten Sensor- und Weltmodellen [NgNg00].
- Eine *serielle Verarbeitung* der Sensoren kann dagegen zu einer Reduzierung der Fehlalarmrate führen, indem die Hypothesen eines Sensors sukzessive an andere Sensoren weitergereicht werden. Mit Hilfe stochastischer Schätzverfahren [HaMc04] (Kalman- [GrAn11, WeBi95], Partikelfilter [GGBF02, RiAG04]) können so die Hypothesen einzelner Sensoren zu einem Gesamtergebnis höherer örtlicher und zeitlicher Qualität fusioniert werden. Allerdings muss das zu erkennende Objekt in allen Sensoren erfassbar sein, was einer Schnittmenge und damit einem reduzierten Einsatzraum gleichkommt.
- Durch Vergleich und Bewertung der Ergebnisse mehrerer, unterschiedlicher Sensoren können ausfallssichere Systeme aufgebaut werden. So lässt sich mit den Sensoren A und B ein 2-fach *redundantes System* aufbauen, dessen Ergebnis nur dann Gültigkeit besitzt, wenn die Einzelergebnisse A und B gleich sind oder sich innerhalb eines Toleranzbandes befinden. Mehrheitsentscheidungen (u.a. 2-aus-3) schränken zwar den Einsatzraum zusätzlich ein (vgl. Schnittmenge der Sensoren  $A \cap B \cap C$  Venn-Diagramm aus Abb. 13), liefern aber auch beim Ausfall eines Sensors noch zuverlässige Ergebnisse, so dass ein operationeller Betrieb möglich ist (engl. *fail-operational*).

Die Wahl eines geeigneten Integrationsprinzips (Abb. 14) ist von der Applikation und deren Anforderungen getrieben [Bonf09, Durr88]:

- Sensoren gleicher Nutzinformation werden mit dem Ziel integriert, ein möglichst zuverlässiges und ausfallssicheres System zu realisieren. Die Einzelergebnisse sind vergleichbar (*konkurrierende* Integration) und können somit einerseits plausibilisiert werden (Redundanz) oder durch stochastische Schätzverfahren zu einem Ergebnis höherer örtlicher und zeitlicher Güte gefiltert werden.
- Heterogene Sensoren liefern sich ergänzende Informationen (Diversität). Derartige Kombinationen z.B. aus Farb- und Wärmebildkameras erweitern so einerseits den Einsatzraum (Tag und Nacht) und liefern andererseits die Möglichkeit den Merkmalsraum zu vergrößern. Werden die Sensoren dabei separat ausgewertet und anschließend zu einem gemeinsamen Situationsbild vervollständigt, so spricht man *komplementärer* Integration. Ein Beispiel hierfür wäre die Personenerkennung tagsüber anhand der Farbe oder abends anhand der Temperatur. Eine gleichzeitige Auswertung

des neuen Merkmalsraums wird als *kooperative* Integration bezeichnet. Sie führt in der Regel zu robusteren Ergebnissen, indem unterschiedliche Eigenschaften genutzt werden können. Eine solche zuverlässige Detektion z.B. anhand von Farbe und Temperatur, wird jedoch mit parallelen Verarbeitungsschritten und damit einem höheren Ressourcenverbrauch erkauft.

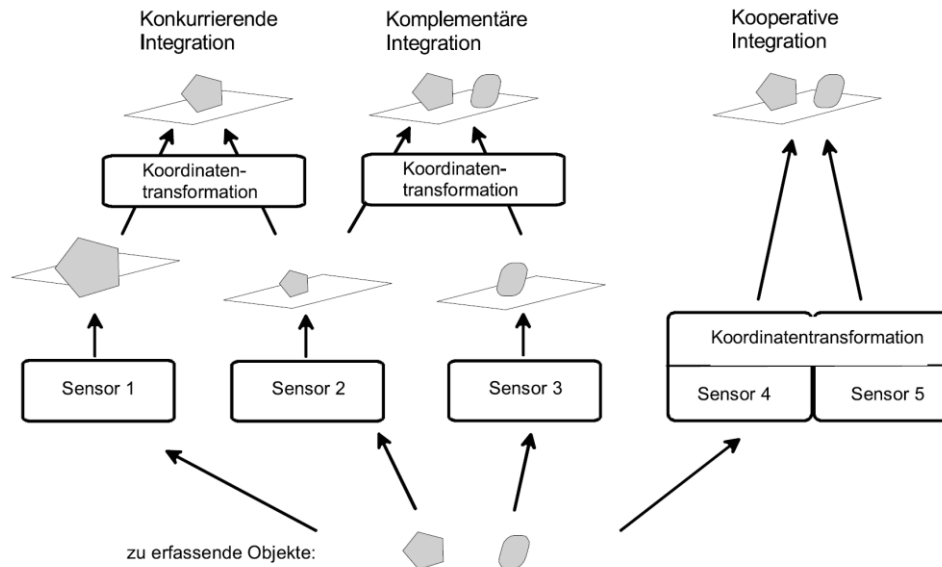


Abb. 14: Unterschiedlichen Möglichkeiten der Sensorintegration nach [BePS06]

### 3.1.2 Modelle und Architekturen

Die Integration von Sensoren und deren Fusion kann auf verschiedene Art und Weise und auf unterschiedlichen Ebenen realisiert werden. Hierzu wurden in [ESWH05, Klei04, LuCh12] verschiedene Modelle und Architekturen verglichen. Nach [LuKa89] kann die Fusion in mehrere Abstraktionsebenen unterteilt werden. „Dabei ist die Fusion auf einer höheren Abstraktionsebene meist effizienter, nicht jedoch notwendigerweise effektiver, da sie mit Datenreduktion und einem Informationsverlust einhergeht“ [BePS06].

Wie in Abb. 15 ersichtlich, wird hierbei zwischen Signal-, Pixel-, Feature- und symbolischer Ebene (engl. *level of representation*) unterschieden:

- Auf der *Signal-Ebene* werden ein- oder mehrdimensionale Rohsignale fusioniert. Da hierbei noch keine Informationen extrahiert wurden, liegen die Signale unverändert, d.h. mit geringer Informationsdichte aber hoher Datenrate vor. Die Datenströme müssen zunächst zeitlich synchronisiert werden und können anschließend gemittelt oder gefiltert werden [Robl00].
- Auf *Pixel-Ebene* werden mehrere Bilder kombiniert. Hierzu müssen die Daten nicht nur zeitlich synchronisiert, sondern auch örtlich zueinander kalibriert werden.
- Auf der *Feature-Ebene* werden aus Bild- oder Sensorsignalen gewonnene Merkmale (u.a. Punkte, Kanten, Flächen) separat extrahiert und mit Hilfe geometrischer Eigenschaften wie Position, Lage und Form beschrieben. Die Einzelergebnisse werden anschließend mit Hilfe von stochastischer Schätzverfahren (Kalman/Partikelfilter) zeitlich und örtlich korreliert und zu Ergebnissen höherer Güte zusammengefasst.

- Auf *Symbolischer-Ebene* werden Detektions- und Klassifikationsergebnisse kombiniert. Erkannten Symbolen oder Objekten wird hierbei eine Detektions-Wahrscheinlichkeit oder Unsicherheit (Konfidenzmaße) zugordnet. Mit Hilfe von *Bayesian Estimation*, *Dempster-Shafer Evidential Reasoning* oder *Fuzzy Logic* können die Konfidenzmaße unterschiedlicher Quellen zu einer resultierenden Gesamtwahrscheinlichkeit und damit i.d.R. zu einer zuverlässigeren Aussage plausibilisiert werden [LILH08].

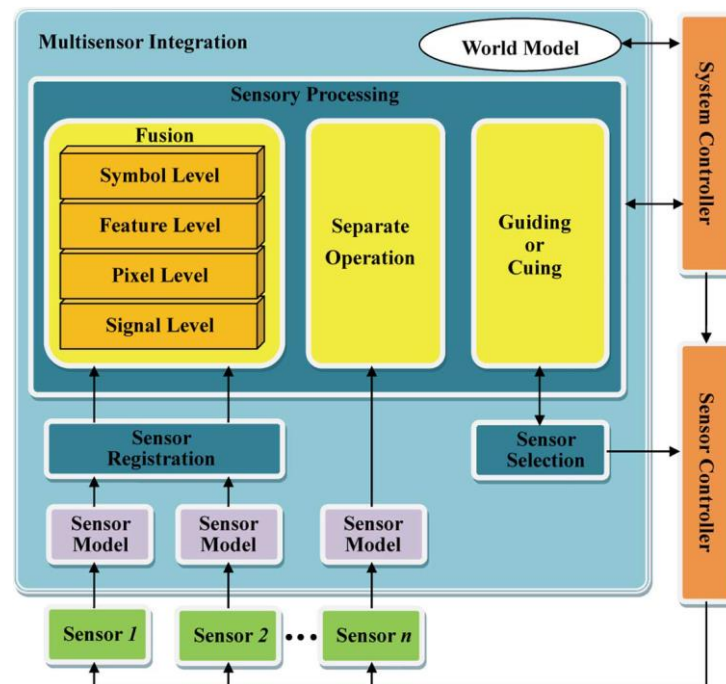


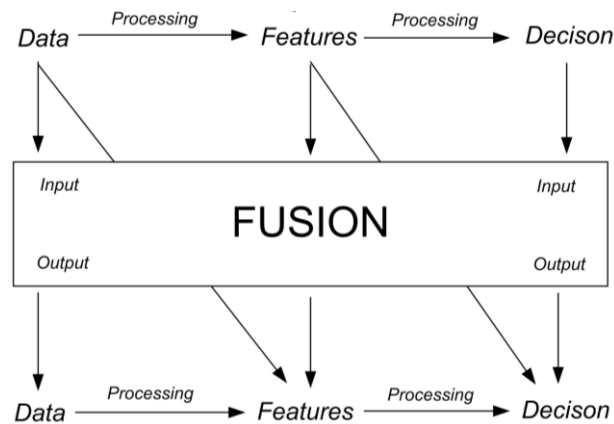
Abb. 15: Multisensor Architektur nach Luo and Kay [LuKa90], [LuCh12]

Basierend auf einem Weltmodell überwacht hierbei der *System Controller* den Zustand der Sensorverarbeitung und greift regelnd in den Fusionsprozess ein. Jeder einzelne Sensor ist über einen *Sensor Controller* steuerbar, was die Auswahl und Konfiguration Sensoren ermöglicht.

Unterschiedliche Abstraktionsebenen der Sensorfusion werden auch im *Input-Output Model* von Dasarathy [Dasa97] vorgesehen. Dasarathy unterscheidet hierbei wie in Abb. 16 aufgezeigt je nach Eingangsdaten zwischen *early*, *late* und *very late fusion*:

- *Early fusion:* umfasst die frühe Verarbeitung oder Fusion von Daten auf Signal- oder Pixelebene mit dem Ziel höherwertige Ausgangsdaten zu gewinnen (DIDO: Data In → Data Out) oder Merkmale abzuleiten (DIFO: Data In → Feature Out).
- *Late fusion:* bezieht sich auf die Verarbeitung auf Merkmalsebene. Als FIFO (Feature In → Feature Out) bezeichnet Dasarathy beispielsweise die Fusion geometrischer Informationen aus der Verarbeitung unterschiedlicher Sensordaten mit dem Ziel eine möglichst genaue und vollständige geometrische Beschreibung zu erlangen. Andererseits können Merkmale auch zur Detektion und Identifikation genutzt werden, indem aktuelle Merkmale mit zuvor trainierten Merkmalsräumen verglichen werden (Feature In → Decision Out).

- *Very Late fusion:*  
spiegelt die höchste Abstraktionsebene wider, wobei rein symbolische Ein- und Ausgangsgrößen betrachtet werden (Decision In → Decision Out).




**Abb. 16:** Einteilung aufgrund Ein- & Ausgangsabhängigkeiten nach [Bak00, Dasa97]

Das in der Fusionsdomäne etablierte JDL-Modell eignet sich gut zur weiteren Begriffsklärung und Identifizierung von Systemkomponenten. Hierfür ist in Abb. 17 schematisch das überarbeitete JDL Version [BSD13, LILH08] dargestellt. Es besteht aus den folgenden fünf Prozessschritten:

- Level 0 (*Sub-Object signal/feature assessment*) beschreibt hierbei die sensornahere Merkmalsgewinnung und umfasst die beschriebenen Signal-, Pixel- und Feature-Ebene.
- Level 1 (*Object/Entity assessment*) bezieht sich auf die Objekterkennung und Zustandsschätzung eines für sich alleine betrachteten Objektes. Hierbei werden die Objekte detektiert, identifiziert, lokalisiert und verfolgt (engl. *tracking*), um ein möglichst vollständiges Lagebild erstellen zu können.
- Level 2 (*Situation assessment*) wertet dieses Lagebild aus, indem die Beziehungen und Wechselwirkungen zwischen einzelnen Objekten und Strukturen berücksichtigt werden.
- Level 3 (*Impact assessment*) prüft die Handlungsalternativen – im Sinne eines Sensor- oder Ressourceneinsatzes – um einen effektiven Informationsgehalt zu gewährleisten.
- Level 4 (*Process assessment*) beschreibt einen iterativen Optimierungsprozess des gesamten Ablaufs. Durch Überwachung und Anpassung der Level 0-3 soll somit während des Betriebes eine Steigerung der Performanz erzielt werden, wie dies u.a. durch eine aktive Steuerung oder Ausrichtung der Sensoren ermöglicht wird [RuPu07].

Das Sensormanagement kann auf Ebene 4 im Sinne einer geschlossenen Regelkreises (engl. *feedback closed-loop*) verstanden werden [XiSv02]. Wie in Abb. 17 anhand des grünen Pfades verdeutlicht, können so die Ergebnisse und Implikationen der Ebenen 0-3 zur weiteren Planung des Sensoreinsatz zurückgeführt werden.

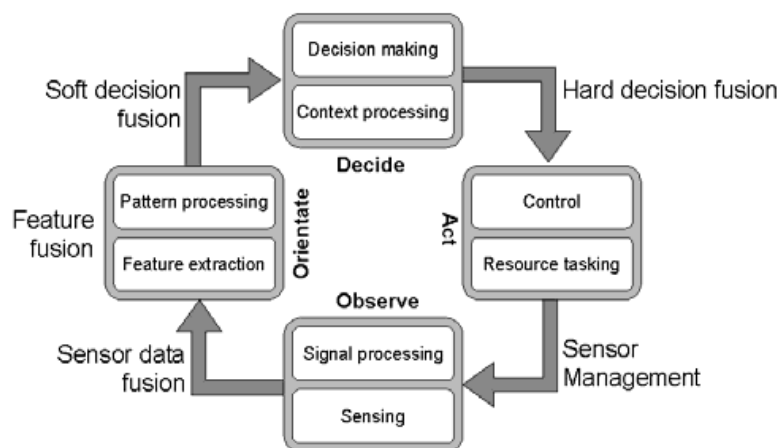


• **Abb. 17:** JDL Modell (Joint Directors of Laboratories) nach [StBW99].

Das **Omnibus-Modell** greift das Modell von Dasarthy auf und überführt es ebenfalls in einen geschlossenen Regelkreis, der dabei aus den folgenden Elementen des *OODA*-Loops [Boyd87] besteht:

- *Observe*: Messen (Wahrnehmung, Signalverarbeitung),
- *Orientate*: Ausrichten (Merkmalsextraktion, Mustererkennung),
- *Decide*: Entscheiden (Kontextverarbeitung, Entscheidung)
- *Act*: Handeln (Steuerung, Ressourceneinsatz)

Die Funktionsblöcke finden sich sowohl im JDL Modell als auch im Wasserfall Modell [HaBD98] wieder. Die Übergänge zwischen den Funktionen sind dabei verschiedenen Funktionsstufen zugeordnet: *Sensor data fusion* entspricht hierbei etwa der bereits vorgestellten *Early fusion*. *Soft decision fusion* ist auf der Ebene der *Late fusion* angesiedelt. *Hard decision fusion* liefert symbolische Ergebnisse und Erkenntnisse die direkt zum *Sensor-Management* genutzt werden können (vgl. *Process Refinement*, JDL-Level 4).



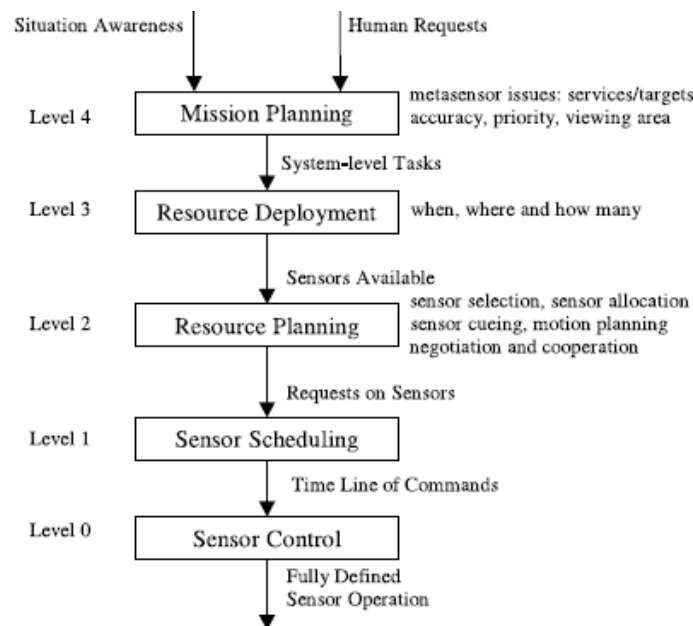
**Abb. 18:** Omnibusmodell nach Bedworth [BeOb00]

Basierend auf oben genannten Methoden wurden mehrere Architekturen für ein Sensormanagement vorgeschlagen [Bena02, HeCo11, Hube09b, Pane08]. Die grundlegenden



Komponenten und Wirkungsweisen ähneln sich hierbei und werden anhand des generischen **Sensormanagers** (Abb. 19) nach [XiSv02] erläutert:

- Auf der höchsten Ebene (Level 4: *Mission Planning*), werden die Aufgaben spezifiziert, ohne dass hierbei Sensor- und Implementierungsdetails betrachtet werden (müssen). Die Aspekte (*metasensor issues*) umfassen hierbei sogenannte Dienstleistungen<sup>14</sup>, die erforderliche Zuverlässigkeit und Genauigkeit, eine Gewichtung der Dienstleistungen sowie die zeitlich-örtliche Beschreibung des Einsatzgebietes.
- Die Ressourceneinsatzebene (Level 3) versucht die abstrakten Anfragen und Anforderungen von Ebene 4 mit den verfügbaren Fähigkeiten (*Sensing Capabilities*) in Einklang zu bringen. Es überwacht hierzu die unterlagerten Ebenen und die Umgebungsbedingungen und kann neue Ressourcen anfordern (Sensoren) sowie eine erneute Planung auslösen.
- Auf der Ressourcenplanungsebene (Level 2) werden einzelnen Sensoren konkrete Aktionen (*Jobs*) zugeordnet. Der Planungshorizont umfasst *Sensor Selection*, *Sensor Cuing*, die integrierte Sensor-Pfad-Planung sowie die Kooperation einzelner Sensoren.
- Auf der Sensorplanungsebene (Level 1: *Sensor Scheduling*) wird in Abhängigkeit der Wichtigkeit einzelner *Jobs* die zeitliche Ablaufsteuerung einzelner Sensoren bestimmt und überwacht. Hierbei können die Sensoren zu unterschiedlichen Zeitpunkten auch für unterschiedliche *Jobs* eingesetzt werden.
- Die Realisierung des *Sensor Controller* findet auf der niedrigsten Ebene 0 statt. Er dient zur Anpassung einzelner Sensoren an gegebene Umwelt- und Plattformzustände und trägt maßgeblich zur Verbesserung des Gesamtprozesses bei. So können bei farbbasierten Videokameras u.a. die folgenden Parameter optimiert werden: Auflösung und Brennweite, Fokus, Belichtungszeit und Gain zur Anpassung von Helligkeit und Kontrast sowie die Regelung des Weißabgleich (Farbtemperatur).




**Abb. 19:** Konzept eines Top-down Sensormanagers nach [XiSv02].

<sup>14</sup> „Which services to perform e.g. search, target tracking, or target updating“ [XiSv02]

## Kombinierte Pfad- und Sensorplanungssysteme

Beim Einsatz von UAVs kann mit modernen Missionssensoren (Gimbal, Abb. 2) nicht nur die Ausrichtung des Sensorsystems selbst, sondern auch Position, Höhe, Lage und Geschwindigkeit der Trägerplattform optimiert werden. Dies ist die Aufgabe *kombinierter Pfad- und Sensorplanungssysteme*.



**Abb. 20:** Schematische Darstellung eines kombinierten Pfad- und Sensorplanungssystems nach [BSD13].

Mit Hilfe von Sensorauflösung, Chipgröße, gewählter Optik sowie Flughöhe und Blickwinkel lässt sich der abgedeckte Bildbereich (engl. *Field of View*, FOV) bestimmen (Abb. 20). Der zu erwartende Informationsgehalt (vgl. Entropie in [Groc02], [Will07], [Hube09b]) setzt den abgedeckten Bildbereich ins Verhältnis zu dem zu beobachtenden Ort oder zu den zu verfolgenden Objekten. Aus dem Abgleich von Beobachtungspunkt und FOV mit Höhen und Geländedaten können mögliche Objektverdeckungen geschätzt werden.

Zum Lösen dieser mehrdimensionalen Optimierungsprobleme werden u.a. die dynamische Programmierung [RBFT99], virtuelle Kräfte (Potentialfeld Methoden) [Bort00], genetische Algorithmen [MiDe07, RKPC02] und marktbasierende Ansätze [LaMa05] eingesetzt.

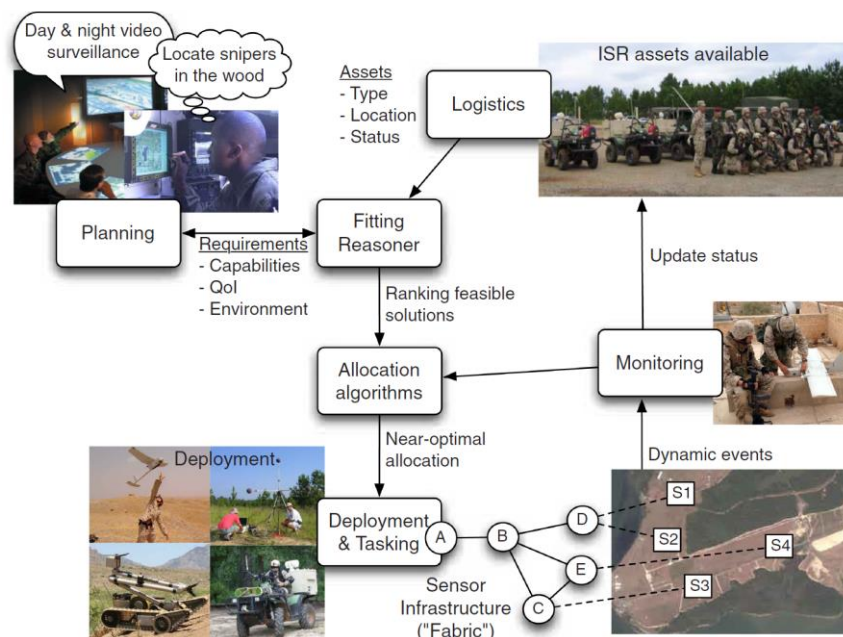
## Ressourcenmanagement

Beim *Ressourcenmanagement* sollen nicht einzelne Plattformen (Ressourcen) für sich allein betrachtet werden, sondern vielmehr ein Nutzen eines Verbunds unterschiedlicher Plattformen betrachtet werden.

Derartige räumlich verteilte Multisensornetzwerke werden u.a. in zivilen und militärischen Sensornetzwerken eingesetzt [CBBG12, ChKu03, HRSS12]. Neben informationstechnischen Aspekten können hierbei auch energetische Gesichtspunkte zum Tragen [ScTS02] kommen. In Command and Control Netzwerken (C2) werden einzelne mobile Plattformen (bemannte und unbemannte Flugzeuge, Fahrzeuge, Schiffe und Einheiten) als Aufklärungsressource beschrieben [PrGo08] und in Datenbanken<sup>15</sup> hinterlegt. Zur optimalen Missionsplanung,

<sup>15</sup> “At even higher levels, the focus shifts toward management of resources against high-level mission objectives. Today, large-scale resource and task allocation, such as tasking dozens of platforms – each with multiple options for sensors and weapon load outs and platform assignments – against dozens of targets, are often undertaken in a largely manual fashion. The scale of these large allocation and tasking functions present significant time and manpower challenges for mission commanders and their staff.” [MuSh12]

Ressourcenauswahl und Ausrüstung werden diese Datenbanken vor und im Laufe der Mission durchsucht und aktualisiert (Abb. 21).



**Abb. 21:** Das *Missions and Means Framework* (MMF) dient zur gezielten Einsatzplanung- und Überwachung von bemannten und unbemannten (Aufklärungs-)/Ressourcen [GPJM08, PrGo08].

### 3.2 Sensordatenauswertung und Bildverarbeitung

In diesem Kapitel sollen die Methoden und Konzepte der Bildverarbeitung zur Umweltwahrnehmung auf Luftfahrzeugen sowie die Einsatzmöglichkeiten einer automatisierten Sensorauswertung näher erläutert werden.

Hierbei werden weniger spezielle Algorithmen betrachtet, sondern vielmehr soll ein generelles Verständnis für den Aufbau und die Wirkungsweise einer computergestützten Sensordatenauswertung vermittelt werden. Beispiele computergestützter Auswertung sind im Versuchskapitel anhand der implementierten und in den Flugversuchsträger integrierten Ketten (Abschnitt 8.4) näher beschrieben.

#### 3.2.1 Aufgaben der Bildverarbeitung

Neben der missionsbezogenen Objektdetektion bzw. Aufklärung kann eine computergestützte Umweltwahrnehmung auf Luftfahrzeugen auch für navigatorische und manipulatorische Aufgaben genutzt werden:

- *Missionsbezogene und aufgabenspezifische Auswertung* deckt sich dabei mit den vorgestellten Anwendungen der Fernerkundung (Kapitel 2.1). Sie umfasst u.a. Überwachungsaufgaben wie das Erkennen und Verfolgen von Objekten, Personen, Fahrzeugen [CLHR14] oder Infrastruktur, die Temperaturprüfung von Stromleitungen und die bildbasierte Lecksuche von Pipelines.

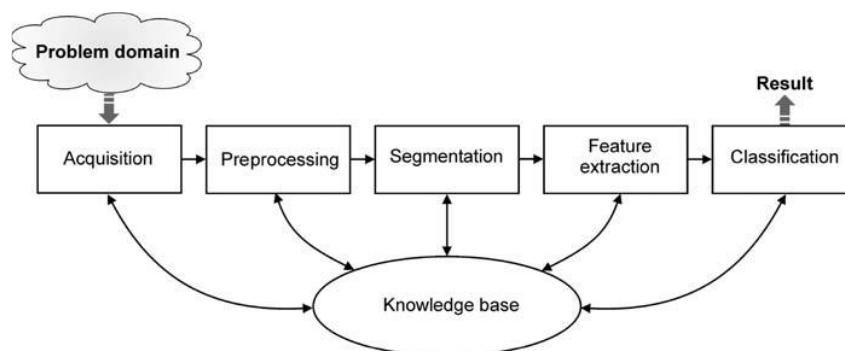
- *Navigatorische* Aufgaben umfassen u.a. die rein missionssensorbasierte Navigation wie das Fliegen entlang von Straßen/Landmarken ohne GPS [NKSW10, ViKe09], die reaktive Hindernisvermeidung sowie automatische Start-/Landevorgänge [MFEX09].
- *Manipulatorische* Aufgaben, wie das Greifen und Ablegen aus der Luft, können häufig durch einen menschlichen Teleoperator nicht ausreichend schnell geleistet werden. Dabei auftretende Latenzen führen zu Totzeiten und damit zu Instabilitäten der unterlagerten Regler [KKAS13, KOMK14], weshalb bereits computergestützte Messsysteme [ALHM14] eingesetzt werden.

Die Sensorausgangsdaten umfassen dabei neben Grauwert- und Farbbildern, Messwerte aus Infrarot- oder Multispektralkameras sowie Entfernungsdaten (LIDAR, RADAR, SAR). Die Auswahl geeigneter Verarbeitungsroutinen hängt vom Sensortyp, der Aufgabe und den Umweltbedingungen ab.

### 3.2.2 Verarbeitungsketten und klassische Bildverarbeitung

Zur Extraktion relevanter Informationen wird in der Regel eine Kette von Verarbeitungsoperationen durchgeführt [Jähn05, Marq11, Prat94, Scot05].

Der Prozess beginnt mit der Aufnahme und der Digitalisierung eines Bildes (engl. *acquisition*). Zur *Vorverarbeitung* (engl. *preprocessing*) zählen neben einer Anpassung von Helligkeit und Kontrast, die Bildrestauration und –rekonstruktion, aber auch Koordinatentransformationen, radiometrische und geometrische Korrekturen und Kalibrierungen. Hierdurch sollen möglichst optimale Bedingungen<sup>16</sup> für die anschließende Analyse und Detektion von Objekten geschaffen werden.



**Abb. 22:** Darstellung der Bildverarbeitung als Prozesskette nach [Marq11, Prat94].

Für die *Segmentierung* (engl. *segmentation*) werden in der Regel eine ganze Reihe weiterer Verarbeitungsschritte benötigt, um mögliche Objekte von anderen Objekten und dem Hintergrund zu unterscheiden. Beispiele für solche (*Filter-)/Operationen* [Jähn05] sind Mittelung und Schwellwertbildung, Kantendetektion oder die Analyse einfacher Nachbarschaften (Farbe, Temperatur, Entfernung).

<sup>16</sup> Verzerrungsarme, zeitlich-örtlich referenzierte Bilder mit „gleichbleibenden“ Weißabgleich, Helligkeit und Kontrast.

Komplexere Muster bzw. *Features* können mit den Methoden der Mustererkennung (engl. feature extraction, [Bish06, Niem03]) berechnet werden. Beispiele wären HOG (Histogram of Oriented Gradients), SURF (Speeded Up Robust Features) und SIFT (Scale-Invariant Feature Transform) Feature-Deskriptoren. Sie werden genutzt, um lokale Strukturen in Bildern zu extrahieren, mit denen eine Objekterkennung und Bildzuordnung ermöglicht wird.

Mit Hilfe morphologischer Operationen kann die Form möglicher Objekte analysiert und verändert werden, indem die Nachbarschaftsrelationen und Segmentgrößen berücksichtigt werden. Diese Objekthypothesen können aufgrund ihrer Formbeschreibung wie Fläche, Umfang oder Füllgrad bereits einer einfachen *Klassifizierung* unterzogen werden. Zuverlässigere, aber auch rechenzeitintensivere Methoden basieren auf dem Abgleich der Hypothesen mit zuvor erlernten oder trainierten Modellen. Klassische Methoden des "flachen Lernens" (engl. *shallow learning*) umfassen beispielsweise das Template Matching oder Support Vector Machines (SVMs) [RHGS17, SiZi15]. Je deutlicher sich die Muster zwischen einzelnen Klassen unterscheiden, umso zuverlässiger ist auch die Entscheidung. Neben der Klassifikation ist mit vergleichenden Methoden auch eine *Identifikation* möglich. Hierbei werden die Hypothesen nicht (nur) auf eine Klassenzugehörigkeit überprüft, sondern es wird vielmehr die Ähnlichkeit zu einem bestimmten zu identifizierenden Objekt untersucht.

Um die Fehlerrate zu minimieren und die räumliche Schätzung von Objekten zu optimieren, kann die Auswertung aufeinanderfolgender Einzelbilder genutzt werden. In einem iterativen Prozessschritt werden hierzu die Systemparameter auf Basis von fehlerbehafteten Beobachtungen geschätzt und iterativ verbessert. Unter Berücksichtigung von Objektbewegungsmodellen können bisherige Hypothesen in den aktuellen Zeitframe prädiert werden (engl. *tracking*). Aus der Korrelation vergangener und aktueller Messungen können die Mess- und Systemmodelle anhand mathematischer Modelle angepasst und aktualisiert werden, wodurch letztlich die Zustandsschätzung optimiert, und die Fehlerfortpflanzung minimiert werden. Zu den bekanntesten mathematischen Verfahren zur stochastischen Zustandsschätzung [ThBF05] zählen Kalman Filter [GrAn11, WeBi95] und Partikel Filter [GGBF02, RiAG04].

### 3.2.3 Deep Learning Ansätze

Traditionelle Methoden zur Objekterkennung und -detektion bei UAVs setzen auf spezielle Merkmale wie SIFT, SURF oder HOG oder basieren auf der Bewertung von Vorder- und Hintergrund und geometrischen Beschränkungen (BLOB). Diese Methoden nutzen lokale Merkmale, Schwellenwerte, Annahmen über die Umgebung oder werden anhand kleiner Datenmengen spezialisiert (*shallow learning*). Daher sind die traditionellen Bildverarbeitungsmethoden anfällig für Fehler und meist nur auf einen sehr begrenzten Zustandsraum anwendbar [OCCH08, PiCD08].

Im Gegensatz zu traditionellen Methoden besteht der Grundgedanke des Deep Learning (DL) darin, dass Objektmodelle, -eigenschaften und -merkmale direkt aus Eingangsbildern gelernt werden. State-of-the-Art Deep-Learning-Verfahren wie CNN (engl. *Convolutional Neural Networks*) und ViT (engl. *Vision Transformer*) erfordern hierfür große Datensätze für das Training der Modelle sowie Computerarchitekturen, die rechenintensive maschinelle Lernalgorithmen schnell und effizient ausführen können.

Dank moderner GPUs bzw. FPGAs und aufgrund der Verfügbarkeit großer annotierter Datensätze haben Deep-Learning-Methoden die traditionellen Methoden in aktuellen Computer-Vision-Wettbewerben wie COCO [LMBH14], ImageNet [DDSL10] oder Pascal Visual Object Classes (VOC, [EGWW10]) deutlich übertroffen.

### Convolutional Neural Networks (CNN)

CNNs sind "tief" im Sinne von "Deep Learning", weil sie aus vielen Schichten von Neuronen bestehen, die Daten verarbeiten. Der Begriff "Faltung" bezieht sich auf die spezielle Art von Operationen, die in diesen Netzwerken durchgeführt werden. Faltungen sind mathematische Operationen, die in diesem Zusammenhang dazu dienen, lokale Merkmale in den Bilddaten zu erkennen. Sie sind besonders effektiv in der Erkennung von Mustern, Konturen und Texturen in Bildern, was sie zu einem Schlüsselement vieler Bildverarbeitungssysteme macht.

CNN-basierte Objekterkennungsmethoden können in zweistufige (regionenbasierte) und einstufige Ansätze unterteilt werden [KSZQ19]:

- *Zweistufige Ansätze*: Diese regionenbasierten Algorithmen wie R-CNN [GDDM14] und Fast(er) R-CNN [RHGS15] identifizieren zunächst Regionen, in denen Objekte erwartet werden, und erkennen dann mithilfe von Convnet Objekte in diesen Regionen.
- *Einstufige Ansätze*: Single-Shot-Detektoren (SSDs) wie YOLO [BoWL20, RDGF15, WaBL22] oder RetinaNet [LGGH17] verwenden einen vollständig faltungsbasierten Ansatz<sup>17</sup>, bei dem das Netzwerk alle Objekte innerhalb eines Bildes in einem Durchgang ("Single-Shot" oder "Look Once") durch das Convnet finden kann.

Zweistufige Modelle können eine etwas höhere Genauigkeit besitzen, während SSDs effizienter (höhere Geschwindigkeit, geringerer Speicherbedarf) sind und dennoch eine gute Genauigkeit aufweisen [VaMe21].

### Vision Transformer (ViT)

ViT [TCSS21] basieren auf der Transformer-Architektur, die ursprünglich für die Verarbeitung von Sequenzen in der natürlichen Sprachverarbeitung entwickelt wurde. Bei der Transformer-Architektur wird die *Attention-Funktion* verwendet [VSPU17], um die Beziehungen zwischen den verschiedenen Positionen einer Sequenz zu modellieren. Im Fall von Vision Transformers wird diese Attention-Funktion auf die Positionen der Eingabevektoren angewendet, um die Beziehungen zwischen den verschiedenen Teilen des Bildes zu erfassen [DBKW21]. Dadurch können Vision Transformers sowohl räumliche als auch globale Abhängigkeiten in den Bildern modellieren und auf komplexe visuelle Muster zugreifen.

Sie sind also nicht wie CNNs räumlichen Einschränkungen der Faltungskerne unterworfen, was dazu beitragen, eine bessere Erfassung globaler Zusammenhänge in den Sensordaten erreicht wird.

---

<sup>17</sup> Folglich gibt es weder separate Klassifizierungs- oder Erkennungsmodule, die miteinander synchronisiert werden sollten, noch sind Regionalvorschläge erforderlich.

### 3.2.4 Vergleich der Methoden

Aufgrund ihrer hohen Erkennungsgenauigkeit und Verallgemeinerungsfähigkeit haben DL-Verfahren (CNN, ViT) herkömmliche Bildverarbeitungstechniken wie geometriebasierte Blob-Detektoren und flache Lernansätze wie SVMs deutlich übertroffen. DL-Verfahren können verwendet werden, um zwischen mehreren Klassen zu klassifizieren (u.a. Personen und Tiere, Fahrzeuge, Verkehrszeichen Gebäude, Bäume) und erreichen auf Referenzdatensätzen eine durchschnittliche Präzision von fast 75% [WaBL22, ZCSG23].

CNNs (EfficientDet [TaPL20], RetinaNet [LGGH17], YOLO [RDGF15]) sind derzeit der Standard für die Objekterkennung in Computer Vision. Sie haben sich in zahlreichen Anwendungen bewährt und können auch auf begrenzter Hardware ausgeführt werden. Es gibt auch speziell entwickelte CNNs für den Einsatz auf mobilen Geräten wie YOLOv4-tiny, UAV-YOLO oder MobileNet, die besonders effizient sind [LWZF20].

ViT [DBKW21, HWCC23, TCSS21] ist ein relativ neues Modell für die Bildklassifizierung und Objekterkennung. Im Vergleich zu herkömmlichen CNNs erzielt ein ViT bei ausreichender Trainingsdatenmenge und Rechenleistung oft bessere Ergebnisse [SrNM21]. Allerdings ist ein ViT auch rechenintensiver als ein CNN. Für den Einsatz auf UAVs muss der Mehrwert einer möglicherweise gesteigerten Zuverlässigkeit sorgfältig gegen die Rechenleistung und die Verfügbarkeit „aufwendig zu erfliegender“ und annotierter Trainingsdaten abgewogen<sup>18</sup> werden.

### 3.3 Analyse bestehender Architekturen und Methoden

Ein automatisierter Sensoreinsatz und eine automatisierte Wahrnehmung können bereits heutzutage bis zu einem gewissen Grad rein computergestützt auf UAVs stattfinden. So vielversprechend die Perspektiven und Erwartungen einer automatisierten Sensorauswertung sind, so schwierig gestaltet sich bisher deren Integration und die unzureichende Zuverlässigkeit bzw. Robustheit unter realistischen Einsatzbedingungen.

Wie in „*Why is real-world visual object recognition hard?*“ [PiCD08] oder in „*Current Challenges in Automating Visual Perception*“ [OCCH08] diskutiert, ist unter realen, dynamischen Umweltbedingungen stets mit Fehldetektionen, nicht erkannten Objekten und ungenau geschätzten Objektpositionen und Größen zu rechnen.

Zuverlässige Ergebnisse sind meist nur für frontale bzw. feste Kameraeinstellungen (u.a. Überwachungskameras) reproduzierbar. Während des Einsatzes von UAVs ist die Bildverarbeitung dagegen mit vielen Herausforderungen verbunden: Bildverschlechterung aufgrund von Beleuchtungs- und Wetterveränderungen, variierende Perspektiven, Hintergrundkomplexität sowie Maßstabs- und Richtungsvielfalt. [VaMe21, WLHT21].

---

<sup>18</sup> Im Rahmen dieser Arbeit fiel die Entscheidung zugunsten von YOLO-Modellen auf Grundlage von CNNs, da Single-Shot-CNNs sowohl zuverlässig als auch auf mobilen Plattformen einsetzbar sind. Vision Transformer Ansätze wären eine Alternative gewesen, wenn ausreichend Rechenleistung und Trainingsdaten zur Verfügung gestanden hätten.

### **Verbesserter, zielgerichteter Einsatz und Fusion von Sensoren:**

Verbesserungen könnten sich aus dem Einsatz multispektraler oder fusionierter Sensoren sowie aus dem zielgerichteten, situationsabhängigen Einsatz der Algorithmen ergeben. Um die bestmöglichen Resultate zu erzielen, sollen einerseits Optimierungen z.B. in Form einer Adaption an gegebene Umweltbedingungen die gesamte Prozesskette einschließen und andererseits soll die Auswertung nicht losgelöst vom Sensoreinsatz betrachtet werden.

Um bereits heutzutage zu Wahrnehmungsergebnissen hoher Güte zu gelangen, sollen drei prinzipielle Möglichkeiten bzw. Konzepte zur Verbesserung der Ergebnisse [HeCo11, LILH08, NgNg00, Nof09] hervorgehoben werden:

- *Sensormanagement*: Der Sensoreinsatz selbst kann optimiert werden.
- *Perzeptionsmanagement*: Die Auswertelgorithmen sollten an die jeweilige Umgebung angepasst werden.
- *Sensor- und Ergebnisfusion*: Die Sensordaten sollten aus unterschiedlichen Sensoren und Algorithmen gewonnen und zu Ergebnissen höherer Güte fusioniert werden.

### **Ressourcenknappheit von Luftfahrzeugen**

Die Limitierungen fliegender Plattformen [SrNM21, TiLY21, WLHT21] hinsichtlich des Gewichts, der Größe und des Energieverbrauchs möglicher Nutzlasten beschränken vor allem bei kleinen UAVs die Auswahl der Sensoren, Reichweite und Bandbreite des Datenlinks (Sendeleistung, Antennen) sowie die Kapazität der Missionsrechner.

Eine *ressourcenoptimierte Auswahl und Anpassung der Algorithmen* müssen daher in Betracht gezogen werden. Dies könnte trotz eingeschränkter Ressourcen eine automatisierte, unverzögerte Sensordatenverarbeitung auf dem UAV ermöglichen, was den Nutzen und Funktionsumfang künftiger UAS erweitern würde.



## 4. Zielsetzung der Arbeit

Das Beispielszenario (Anhang) verdeutlicht typische Aufgabenstellungen, Umgebungsbedingungen und Einsatzszenarien, die durch künftige UAS abgedeckt werden sollen. Anhand des Szenarios wurden die Anforderungen an das UAS und die benötigten Sensoren sowie die erforderlichen Methoden und Algorithmen zur Datenverarbeitung abgeleitet.

Die in diesem Kapitel erstellte Liste der Anforderungen sowie die Forschungsfragen dienen im Weiteren zur konzeptionellen Entwicklung (Kapitel 5), zur Methodenauswahl (Kapitel 6 und Kapitel 7) sowie zur Evaluierung des vorgeschlagenen Ansatzes (Kapitel 9).

Sie werden daher immer wieder aufgegriffen sowie detaillierter erläutert und bilden die Ausgangslage für das Evaluierungskonzept und die Untersuchungsgegenstände (Kapitel 8).

### 4.1 Anforderungen an die Sensorauswertung für unbemannte Flugsysteme

Resultierend aus der vorausgegangenen Analyse bestehender Systeme können die folgenden systematischen und funktionalen Anforderungen hinsichtlich des Sensoreinsatzes und der Sensordatenverarbeitung künftiger, unbemannter Systeme<sup>19</sup> abgeleitet werden:

- a) Die *Zuverlässigkeit der Bildauswertung sollte den Fähigkeiten eines Bildauswerters entsprechen*, damit ein automatisierter Einsatz auch unabhängig vom Datenlink und unter kritischen Missionsumständen möglich wird.
- b) Für unterschiedliche Umweltkonstellationen *vorkonfigurierte Ketten aus Sensoren und Algorithmen* sollen so bewertet und ausgewählt werden, dass eine *optimale Anpassung an die jeweiligen Umweltbedingungen* einerseits und die verfügbaren *Rechnerkapazitäten* andererseits ermöglicht wird.
- c) Das System soll durch *neue Sensoren oder Software-Module verbesser- und erweiterbar* sein. Das Ziel einer solchen emergenten Softwarearchitektur ist das *stetige und gezielte Verbessern und Wachsen der Wahrnehmungsfähigkeiten* über der Entwicklungs- und Einsatzzeit ohne das bisherige System verwerfen oder neu entwickeln zu müssen.
- d) Bei Ausfällen oder Einschränkungen einzelner Sensoren oder Hard- und Softwarekomponenten sollte eine (Teil-)Funktionalität gewährleistet sein, um einen möglichen Einsatzabbruch oder sogar den Verlust des UAVs zu verhindern. Daher sollten entsprechende Redundanz und Fehlertoleranz in das Systemdesign und die Systemarchitektur eingebunden werden.
- e) Die Auswertung der Missionssensoren sollte *auf dem UAV* stattfinden. Dies beschleunigt den Auswerteprozess und ermöglicht datenlinkunabhängige Entscheidungen auf dem Fluggerät, wodurch ein höherer Grad an Autonomie erreicht wird.

---

<sup>19</sup> Teile der Anforderungsliste sind auch für aktuelle UAS, bemannte Luftfahrzeuge sowie UxS gültig.

- f) Je nach Verfügbarkeit der Ressourcen sowie Anzahl und Wichtigkeit der Aufgaben, soll das System *zwischen zuverlässigen oder ressourcensparenden Ketten wechseln*.
- g) Zukünftige autonome UAS sollten in der Lage sein, mit Hilfe des MMS sowohl den Sensoreinsatz als auch die Sensordatenauswertung eigenständig zu koordinieren. Dafür ist eine *Beschreibung der Sensor- und Wahrnehmungsfähigkeiten* erforderlich.
- h) Neben einer *benutzerfreundlichen, serviceorientierten Schnittstelle zur Auswahl von Wahrnehmungsfähigkeiten* soll der Systemzustand dem Operateur transparent<sup>20</sup>, erklärbar und nachvollziehbar dargelegt werden. Nur so kann dieser bei ungeeignet guten Ergebnissen zielführend eingreifen.
- i) Neben dem Expertenwissen der Entwickler sollen auch Erfahrungswerte des Benutzers bei Bewertung und Auswahl von Handlungsalternativen einfließen. *Expertenwissen* soll vorab in den *Kettenmodellen hinterlegt* und später *aktualisierbar* sein.
- j) Zur Verbesserung der Sensorqualität und Wahrnehmungsergebnisse soll das System *Verbesserungsschläge selbstständig vorschlagen* können. So soll das System selbstständig analysieren, inwieweit Sensoreigenschaften wie Reichweite, Auflösung, Fokus oder perspektive Anforderungen durch eine gezielte Änderung des Plattformzustandes positiv beeinflusst werden können.
- k) Die *Fusion von Sensordaten und Ergebnissen* soll explizit vorgesehen sein. Durch Validierung bzw. Plausibilieren und Filterung sollen so möglichst zuverlässigere Ergebnisse fusioniert werden.
- l) Der Systementwurf soll sich auf weitere Plattform-Sensor-Konfigurationen übertragen und sich zudem auch auf künftige *Multi-UAV Anwendungen anpassen* lassen.

## 4.2 Forschungsfragen

Je nach Einsatzszenario und zur Reduzierung Arbeitslast der Operateure sollen künftige UAS zunehmend automatisiert bzw. autonom einsetzbar sein. Allerdings benötigen aktuelle UAS zur Missionsdurchführung noch mehrere Operateure. Üblich sind Flugführungsoperateure und Sensoroperateure- und Auswerter sowie gegebenenfalls zusätzliche Kommunikationsoperateure (siehe KZO in Abb. 5 und LUNA in Abb. 23). Aufgaben die bisher vom Menschen ausgeführt wurden, können jedoch zunehmend durch computergestützte Subsysteme bereitgestellt werden. Mittelfristig wäre sogar die Führung (mehrerer) UAVs durch weniger Personal denkbar.

Bestehende Architekturen und Ansätze reichen dabei nicht aus, um den Wirkkreis zur Führung künftiger UAS (Abb. 24: Wahrnehmen, Entscheiden, Führen) auch unter erschwerten Einsatzbedingungen zu schließen. Darüber hinaus wird dem Zusammenspiel zwischen automatischer Sensordatenauswertung und intelligenten Teilsystemen zur Flug- und Missionsdurchführung für künftige autonome Flugsysteme essenzielle Bedeutung zugesprochen [Depa13, MuSh12].

---

<sup>20</sup> Durch Transparenz sollen dabei interne Zustände, Prozesse und Entscheidungen des internen Systems von außen für den Operateur oder ein intelligentes MMS beobachtbar sein.

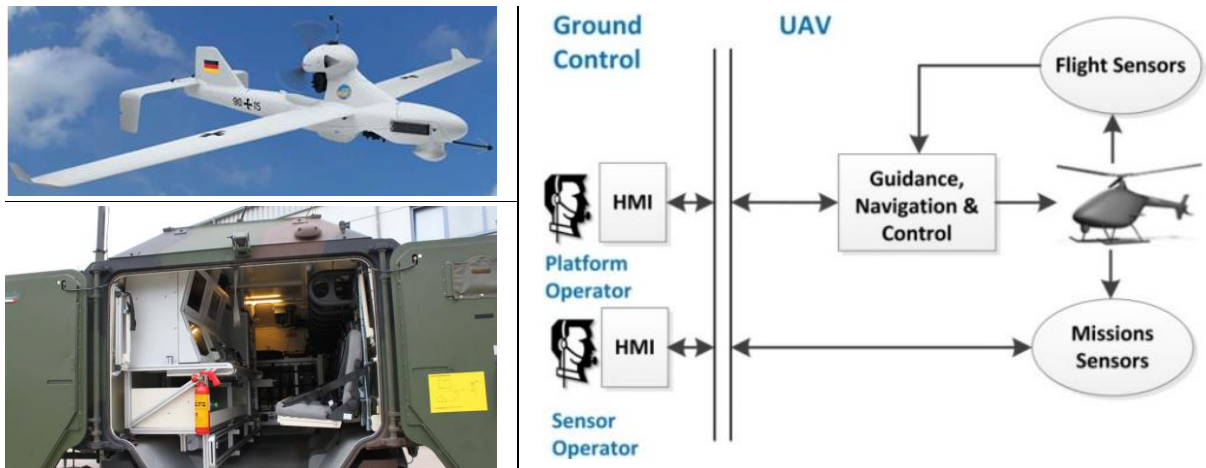


Abb. 23: Traditionelle UAV-Führung mit mehreren Operateuren, am Beispiel des LUNA-UAS<sup>21</sup> [RuSt13a].

Es wird also ein innovatives, ganzheitliches Systemkonzept benötigt, um den Grad der Automation weiter zu steigern. Hierbei stellen sich folgende Forschungsfragen:

- *Wie könnte ein ganzheitliches Systemkonzept aussehen?*
- *Mit welchen Methoden wäre eine prototypische Umsetzung möglich?*
- *Kann mit Hilfe des Systemkonzepts ein Sensoreinsatz und dessen Auswertung so weit automatisiert werden, dass eine dem menschlichen ähnliche oder bessere Erkennungsleistung auch unter variierenden und erschwerten Umwelt- und Plattformzuständen möglich ist?*

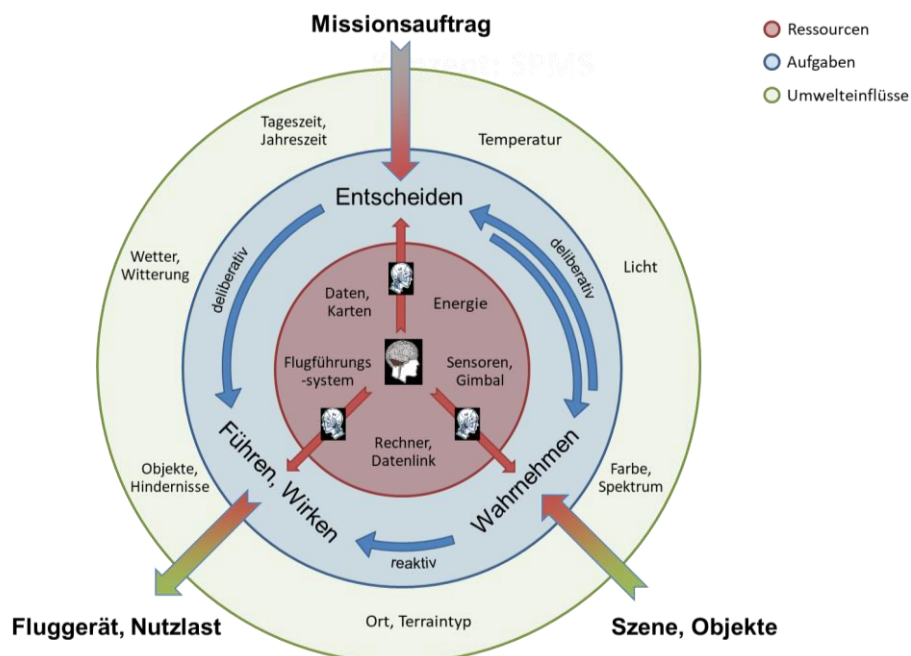


Abb. 24: Wirkkreis zur Führung von UAS: Entscheiden, Wahrnehmen und Führen.

<sup>21</sup> [https://www.panzer-modell.de/referenz/in\\_detail/yak\\_bks/006g.jpg](https://www.panzer-modell.de/referenz/in_detail/yak_bks/006g.jpg)



## 5. Systemkonzept

Um die Anforderungen aus Abschnitt 4.1 zu einzuhalten, müssen sowohl die Sensoren als auch die Algorithmen gezielt und ressourcensparend eingesetzt werden. In diesem Kapitel wird hierfür ein ganzheitliches Systemkonzept abgeleitet, welches das Zusammenspiel zwischen Missionsmanagement und Sensor-/Wahrnehmungsebene ermöglicht.

Das Sensormanagement umfasst hierbei die Integration und Fusion von Sensoren sowie deren Konfiguration, Ausrichtung und Auswahl während des Fluges. Es dient somit zur Verbesserung der unverarbeiteten „Sensorrohdaten“.

Das Perzeptionsmanagement soll eine Anpassung der Verarbeitungsroutinen an die aktuellen Umweltgegebenheiten und unter Berücksichtigung der verfügbaren Ressourcen im Sinne einer adaptive Vorkonfiguration und Verkettung einzelner Module zu komplexen Wahrnehmungsaufgaben ermöglichen. Eine aufgaben- bzw. fähigkeitsbasierte Schnittstellenlösung soll darüber hinaus einen entsprechenden Abstraktionsgrad bieten, der einerseits einen vereinfachten Einsatz einer automatisierten Sensordatenauswertung ermöglicht.

Im Folgenden werden zunächst das traditionelle Schema zur UAV-Führung sowie das neue mehrschichtige Konzept vorgestellt. Um eine Realisierung und Evaluierung des Konzeptentwurfs zu ermöglichen, schließt das Kapitel mit der Fokussierung im Rahmen dieser Arbeit.

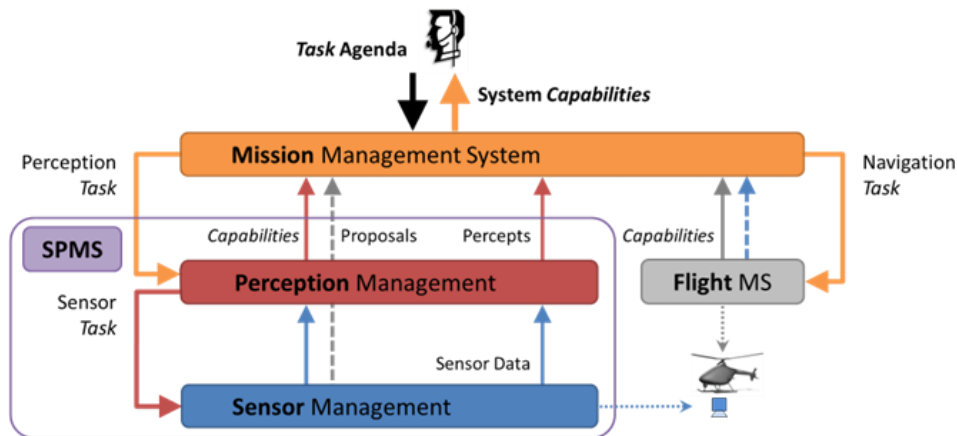
### 5.1 Entwurf des Gesamtsystems

Das vorgeschlagene Gesamtsystem (Abb. 25) umfasst Teilsysteme zur Entscheidungsfindung & Missionsdurchführung (MMS, orange) und unterlagerte Systeme zur Flugführung (FMS, grau) einerseits und andererseits die Möglichkeiten eines optimierten Sensoreinsatzes sowie einer automatisierten Auswertung (engl. *Sensor- and Perceptionmanagement System*, SPMS, violett).

#### Fähigkeitskonzept und auftragsbasierte Führung

Die jeweiligen Fähigkeiten werden von den einzelnen Subsystemen kontinuierlich ermittelt und hinsichtlich ihrer Ausführbarkeit und Durchführbarkeit überwacht.

Die Teilfähigkeiten werden explizit an übergeordnete Schichten weitergegeben, wodurch sich kombinierte, höherwertige Fähigkeiten wie das „Verfolgen von Objekten“ ergeben. Hierfür sind neben Wahrnehmungsfähigkeiten (Vorverarbeitung, Segmentierung, Erkennung, Tracking), untergeordneten Sensorfähigkeiten (Konfiguration der Sensoren, Blickrichtungssteuerung) sowie Flugführungsfähigkeiten (Berechnung, Einhalten von Flugbahnen) erforderlich.



**Abb. 25:** Systemkonzept bestehend aus Mission Management System, Flight Management System, Perception-Sensor Management System (SPMS).

Aus den aktuell verfügbaren Fähigkeiten des Gesamtsystems wählt der Operateur eine oder mehrere gewünschte Fähigkeiten aus. Zusätzlich kann er die Aufgabe über Ort, Objekt und Zeitangabe näher spezifizieren und mit Prioritäten in einer „Task Agenda“ ablegen. Diese Agenda wird vom *Mission Management System* wie folgt zerlegt:

- Eine Flugführungsaufgabe („Navigation Task“) wird ans *Flight Management System* weitergereicht und dort mit Hilfe des Autopilotensystems in ausführbare Sollgrößen für die integrierten Regelsysteme übersetzt. Am Beispiel der Fähigkeit zur „Suche nach Personen in einem bestimmten Gebiet“ wäre das FMS für die Generierung eines auf das Fluggerät angepassten Flugplans (Punktemuster, Geschwindigkeit, Höhe, Krümmungsradien) verantwortlich.
- Die Wahrnehmungsaufgaben („Perception Task“) werden zunächst an das *Perception Management System* (PMS) weitergereicht und dort weiter zerlegt. Basierend auf den integrierten Sensoren und den implementierten Algorithmen ergeben sich potenzielle Verarbeitungsketten (Abb. 27). Falls geeignete Ketten gefunden werden, so stellen diese darüber hinaus Anforderungen an die Missionssensorik und benötigen zusätzlich Ressourcen wie Rechnerkapazitäten oder Arbeitsspeicher.
- Die Anforderungen werden als sogenannten „Sensor Tasks“ an das *Sensor Management System* (SMS) weitergereicht (vgl. Übergang rot-blau in Abb. 25). Das SMS ist einerseits für die Konfiguration der verbauten Sensoren und andererseits für Steuerung der Blickrichtung mit Hilfe des Gimbals verantwortlich.

Die an das PMS zurückgelieferten Sensorrohdaten werden dort von den Ketten ausgewertet und in Form von Wahrnehmungsergebnissen (*Perzepten*) an das MMS weitergereicht. Die Perzepte dienen zur Flugführung (visuelle Flugführung) sowie zur höherwertigen Missionsplanung und Missionsdurchführung (Situationsanalyse, Objekt- bzw. Zielerkennung).

Je nach Verfügbarkeit der Fähigkeit, Priorität, Ressourcenverbrauch, Nähe zum Einsatzort oder verbleibender Zeit sollen die Teilaufgaben bewertet, sortiert und abgearbeitet werden. Der Fortschritt einzelner Aufgaben, die verfügbaren Systemfähigkeiten sowie die Flug- bzw. Sensorzustände sollen zudem kontinuierlich berechnet sowie überwacht werden und stets vom

Operateur oder MMS abrufbar sein. Hierdurch sollen mögliche Probleme zeitnah erkannt und notwendige Änderungen an der Agenda vorgenommen werden können.

### **Strikte Aufgabenteilung und Verbesserungsvorschläge**

Eine Besonderheit des Konzeptes ist die *strikte Trennung zwischen FMS und SMS*. Aus sicherheitsrelevanten Gesichtspunkten ist einerseits ein direkter Zugriff des SPMS auf Flugparameter wie Geschwindigkeit, Höhe oder Ort nicht vorgesehen. Andererseits ist die direkte Interaktion des FMS mit dem Gimbal bzw. Sensoren untersagt. Somit verbleibt die Konfiguration der verbauten Sensoren, Objektive und insbesondere die Ansteuerung des Gimbals Aufgabe des SMS. Hierdurch sollen mögliche Fehlerquellen oder Ressourcenkonflikte wie widersprüchliche oder doppelte Ansteuerungsbefehle per Design ausgeschlossen werden.

Zur Optimierung des Sensoreinsatzes sowie zur Adaption der Algorithmen werden Flugzustände wie Flughöhe, Geschwindigkeit oder Position berücksichtigt. Im Rückkehrschluss könnten diese Parameter genutzt werden, um Verbesserungsvorschläge in Form sogenannter „*Navigation Proposals*“ zu generieren:

- *Anpassung der Flughöhe*: Dies dient u.a. dazu, die Reichweite aktiver Sensoren nicht zu überschreiten und die Bodenauflösung bei Kamerasystemen zu verbessern.
- *Reduzierung der Fluggeschwindigkeit*: Sie kann dazu beitragen die Bewegungsunschärfe in Kameraaufnahmen zu reduzieren und andererseits die örtliche Auflösung von Entfernungsmessungen zu verbessern.
- *Flugmanöver und Flugmuster*: Zur Verbesserung der Sensor-/Bildstabilisierung tragen möglichst ruhige Flugphasen oder idealerweise ein „Schwebezustand“ bei.
- *Lage- und Positionsänderung*: Hierdurch lassen sich Verdeckungen vermeiden oder gewünschte Perspektiven erreichen.

Ob, wann und auf welche Art und Weise diese Vorschläge umgesetzt werden können, hängt vom Missionsablauf, den verbleibenden Ressourcen (Treibstoff, Energie) sowie Sicherheitskriterien ab. Sie sind folglich durch das MMS zu prüfen, und falls durchführbar, anschließend an das FMS weiterzureichen. Ein direkter Zugriff auf das Fluggerät ist nicht wünschenswert und dank obiger Trennung von PSMS-FMS per Design ausgeschlossen.

## **5.2 Verarbeitung von Wahrnehmungsaufträgen**

Im Folgenden werden die Perzeptions- und Sensormanagementschichten gemäß Abb. 26 detaillierter erläutert werden:

- Das PMS besteht aus den Komponenten *Perception Solver (PS)*, *Processing Coordinator*, *Resource Monitor* und dem *Result Validator*.
- Über das SMS werden die unterlagerten Subsysteme zur Sensorkonfiguration (*Sensor Configurator*) und Blickrichtungssteuerung (*Gimbal Control*) vom *Sensor Planner (SP)* angesteuert und überwacht. In dieser zentralen Planungskomponente (SP) sind die Sensorfähigkeiten hinterlegt und müssen zur Laufzeit kontinuierlich auf ihre Gültigkeit

hin überprüft werden. Zudem sollen dort die unterschiedliche Sensoraufgaben (*Sensor Tasks*) in Form zeitlich-örtlicher Sensoreinsatzpläne aufeinander abgestimmt werden.

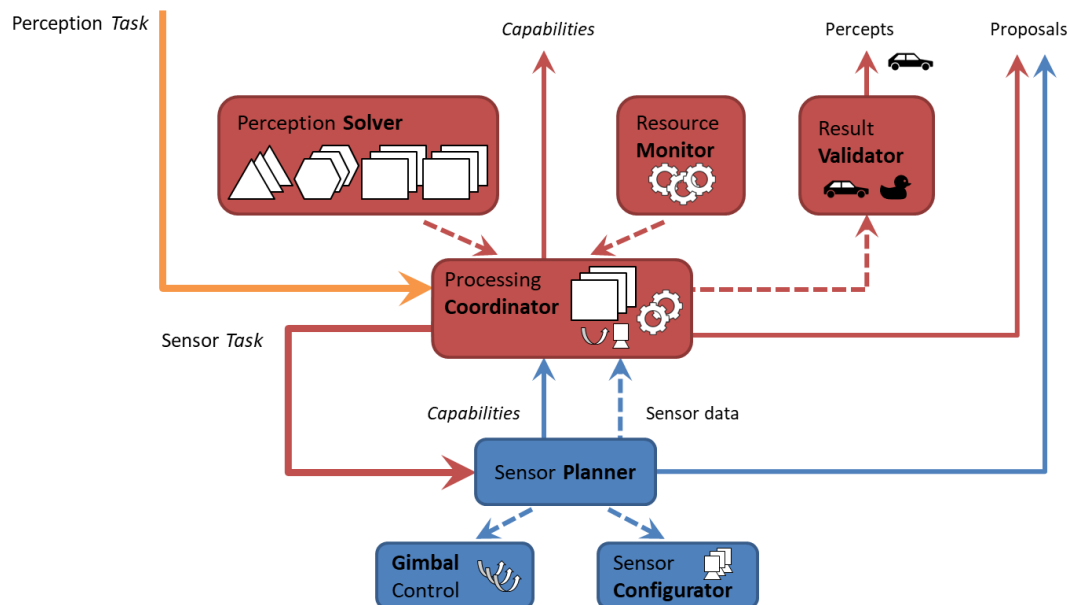


Abb. 26: Detaillierte Darstellung der Perzeptions- und Sensormanagementschichten.

Im *Perzeption Solver* ist das *Hintergrundwissen* über die implementierten Ketten hinterlegt:

- Welche Aufgabe erfüllt die Kette?
- Wie funktioniert die Kette? Aus welchen Modulen ist die Kette aufgebaut?
- Welche Randbedingungen, Annahmen und Ressourcen benötigt die Kette?
- Wie kann die Kette gesteuert und angepasst werden?

Mit Hilfe dieser Informationen kann der *Perzeption Solver* den gesamten Wahrnehmungsraum, d.h. die Summe aller möglichen Wahrnehmungsketten (Abb. 27), aufspannen.

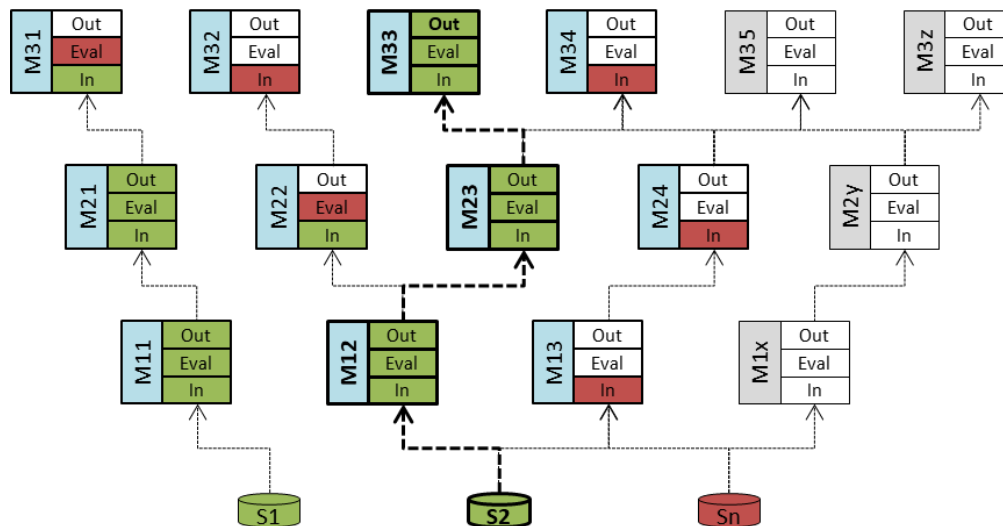
### 5.3 Auswahl geeigneter Sensoren und Algorithmen

Die Auswahl geeigneter Ketten kann an der schematischen Darstellung des Wahrnehmungsraums als hierarchischer *Perzeption-Module-Graph* (Abb. 27) verdeutlicht werden. Module auf höchster Ebene entsprechen Klassifikationsmodulen<sup>22</sup>. Dagegen befinden sich auf den unteren Ebenen der Sensoreinzug und sensornahe Vorverarbeitungsmodule.

Vom MMS gestellte Wahrnehmungsaufgaben (*Perzeption Tasks*) werden vom *Perzeption Solver* hinsichtlich einer prinzipiellen Durchführbarkeit analysiert. Eine solche Aufgabe beschreibt das wahrzunehmende Objekt, eine rein sensorische Aufgabe oder die Aufforderung „alle aktuell möglichen Wahrnehmungsfähigkeiten“ zu prüfen. Hierbei können zusätzliche Vorgaben, wie der präferierte Sensortyp getroffen werden. Je nach Klassifikationstyp und weiterer Vorgaben kann so der Lösungsraum nach alternativen Ketten durchsucht werden.

<sup>22</sup> U.a. Ketten zur Objekterkennung (Personen, Fahrzeuge) und zur Hindernisvermeidung (Abschnitt 8.4).





**Abb. 27:** Der *Perception-Module-Graph* wird aus den *Verarbeitungsmodulen M* und den *Sensordatenquellen S* aufgebaut und dient zur schematischen Darstellung des Wahrnehmungsraums aller (redundanten) Ketten. M1x bildet dabei eine Kette, die auf fusionierte Ausgangsdaten (S2, Sn) zurückgreift.

Redundante Ketten werden vom *Perception Coordinator* anhand benötigter Ressourcen, Sensoranforderungen und durch Abschätzung der erwarteten Modul-/Kettenleistung evaluiert:

- Ketten die nicht installierte, defekte oder momentan nicht geeignete Missionssensoren benötigen, sollen so bereits herausgefiltert werden. Im Beispiel in Abb. 27 wird aufgrund des rot dargestellten Sensoreingangs von Modul M13 eine ganze Kette bestehend aus den Modulen M13, M24 und M34 als nicht ausführbar deklariert.
- Die verbleibenden Ketten K1 (M11, M21, M31), K2 (M12, M22, M32) sowie K3 (M12, M23, M33) werden ausgehend von der sensornahen Vorverarbeitungsschicht (M1x) über die Merkmalschicht (M2y) bis hin zur Detektionsschicht (M3z) auf ihren Ressourcenverbrauch sowie ihre erwartete Zuverlässigkeit überprüft [RuSt12].
- Für Module der mittleren Schicht (Merkmalschicht, M2y) werden häufig Annahmen über das zu findende Objekt, die Umwelt und den Vorder- bzw. Hintergrund getroffen. Sind diese Annahmen für den aktuellen Kontext nur teilweise oder nicht erfüllt, so fällt die vorhergesagte Modul- bzw. Kettenleistung gering aus. Im Beispiel scheidet K2 (S2-M12-M22-M32) aus und wird nicht weiter geprüft.
- Die Module zur Mustererkennung der oberen Ebenen (M31 bis M3z) sind dagegen meist nicht mehr so stark von der Umwelt beeinflusst. Allerdings kann hier der Vergleich mit hinterlegten Trainingsdaten hohe Anforderungen an den Missionsrechner stellen. Im Beispiel ist der geschätzte Ressourcenverbrauch des Modul M31 so hoch, dass die mögliche Kette K1 (S1, M11, M21, M31) insgesamt zu viel Rechenzeit beansprucht. K3 hingegen kann mit limitierten Ressourcen ausgeführt werden.

Der Evaluierungsprozess wird immer dann ausgeführt, sobald neue Wahrnehmungsaufgaben hinzukommen, alte Aufgaben abgearbeitet sind, Ressourcen freigegeben werden, sich der Umweltzustand ändert oder eine durch den Operator oder MMS vorgegebene Periode verstrichen ist.

Um eine gleichzeitige Ausführung mehrerer Ketten und damit eine optimale Ausnutzung der verfügbaren Ressourcen zu ermöglichen, wird neben der Bestimmung der besten Kette eine Rangfolge der Ketten unter Berücksichtigung mehrerer Kriterien erstellt (Abschnitt 7.2: „*Winner-Determination Function*“).

#### 5.4 Validierung von Ergebnissen

Falls entsprechende Ressourcen vorhanden sind, können redundante Ketten<sup>23</sup> gleichzeitig ausgeführt werden. Unterschiedliche Ergebnisse könnten so zu validierten, robusteren und genaueren Gesamtergebnissen fusioniert werden (vgl. Abschnitt 3.1.2).

Im Systemkonzept ist hierfür der *Result Validator* vorgesehen:

- Ergebnisfusion (*Late-Fusion*): Mit Hilfe stochastischer Zustandsschätzer wie Kalman [GrAn11, WeBi95] oder Partikelfilter [GGBF02, RiAG04] können fehlende oder ungenaue Prädiktionen/Schätzungen korrigiert und örtlich verbessert werden.
- Validierung (*Very-Late Fusion*): Durch ein redundantes Entscheidungssystem ("2 aus 3 Entscheidungen") und durch Plausibilitätskontrollen anhand situativen bzw. kontextualen Wissens z.B. in Form von Szenenbäume sollen fehlerhafte Detektionen oder Ketten erkannt und von der Ergebnisfusion ausgeschlossen werden.

Neben der Ergebnisverbesserung dient der *Result Validator* zur *Qualitätskontrolle*. Die Bewertung aktueller Kettenergebnisse könnte in den Entscheidungsprozess als *Ergebnisfeedback* integriert werden, indem zuverlässige Ketten mit einem Bonus und unzuverlässige Ketten mit einem Malus versehen werden.

#### 5.5 Zusammenfassung und Fokussierung

Neben dem Entwurf des Systemkonzeptes soll im Rahmen dieser Arbeit auch dessen prinzipielle Machbarkeit nachgewiesen werden (Kapitel 9). Kernstück des Konzeptes ist die situationsabhängige Auswahl geeigneter Algorithmen und Sensoren. Für eine erste Umsetzung in Form eines Prototyps (Kapitel 8) und eine anschließende Evaluierung des Konzeptes sind

- die umwelt- und situationsabhängige Repräsentation der Sensor- und Wahrnehmungsfähigkeiten durch Modellierung der Kettenleistung (Kapitel 6) und
- die Koordination und Selektion der Wahrnehmungsketten (Kapitel 7)

essenziell. Die Aufgaben des *Result Validator* sowie das Zusammenspiel SPMS-MMS wurden im Zuge der wissenschaftlichen Analyse und des Konzeptes zwar explizit berücksichtigt. Für eine prototypische Implementierung und Aus- bzw. Bewertung des Systemkonzeptes sind diese Systemkomponenten weniger maßgeblich und wurden daher im Rahmen dieser Arbeit nicht implementiert.

---

<sup>23</sup> unterschiedliche Sensorprinzipien und -perspektiven, Methoden, Trainingsdaten

## 6. Modellierung der Kettenleistung


Wie im Konzeptentwurf vorgestellt, soll aus möglichen Alternativen die aktuell am geeignetsten Ketten ausgesucht werden. Je nach Auswahlwahlkriterium soll so eine Adaption des Wahrnehmungssystems an äußere Randbedingungen (Umwelt) unter Berücksichtigung verfügbarer Ressourcen erreicht werden. Hierfür soll die erwartete Kettenleistung und der Ressourcenverbrauch vorab anhand von Ketteneinsatzmodellen berechnet werden.

Basierend auf systemischen Anforderungen (Kapitel 4) werden in diesem Kapitel zunächst die Randbedingungen und Ziele der Kettenmodellierung (Abschnitt 6.1) konkretisiert. Hierauf abgestimmt werden mögliche Modellierungs- und Inferenzmethoden (Abschnitt 6.3) anhand von Modellierungskriterien (Abschnitt 6.2) verglichen.

Dabei zeigt sich, dass die Modellierung der Ketteneinsatzräume (Abschnitt 6.6) mithilfe von Bayesschen Netzen (Abschnitt 6.4) aufgrund konzeptioneller Eigenschaften (Abschnitt 6.5) besonders vorteilhaft ist.

### 6.1 Ziele der Kettenmodellierung

Leistung und Ressourcenverbrauch sind üblicherweise kettenspezifisch und hängen von der Missionsaufgabe<sup>24</sup>, äußeren Einflüssen (Umwelt<sup>25</sup>) und dem Sensor- bzw. Plattformzustand<sup>26</sup> ab (Abb. 28).



**Abb. 28:** Kettenmodellierung: Leistung in Abhängigkeit äußerer Randbedingungen.

Das Ziel besteht darin, den Kontext und die Einflüsse so zu modellieren, dass die Leistung einer Kette mindestens so gut abgeschätzt werden kann, dass sie mit der vorhergesagten Leistung anderer Ketten vergleichbar ist (Abschnitt 9.2.6). Wünschenswert ist zudem die im Konzept (Abschnitt 5.1) vorgesehene Generierung von Vorschlägen. Diese sollen aus den Modellen berechnet und an das MMS in Form von Plattformzuständen (Flugmuster, Position, Höhe, Geschwindigkeit) und an das SMS in Form von Perspektiven, Auflösungen, Wiederholraten weitergereicht werden können.

<sup>24</sup> Objektsuche (Hindernis, Fahrzeug, Person, Gegenstände), Identifikation, Live-Videobildübertragung.

<sup>25</sup> Unter-/Hintergrund, Tages-/Jahreszeit, Szeneninhalte.

<sup>26</sup> Flugzustand (Höhe, Geschwindigkeit, Lage, Flugmuster), Zustand und Ausrichtung der (Missions-) Sensorik/Optik, Verfügbarkeit der Missionsrechner, Bussysteme, Schnittstellen, Qualität der Positionsbestimmung und des Kartenmaterials.

Den systematischen Anforderungen (Abschnitt 4.1) und dem Konzeptentwurf entsprechend, sind hierbei die folgenden Grundsätze zu beachten:

- Eine explizite Trennung von Kettenimplementierung und Leistungsmodellierung soll Erweiterbarkeit, Ausfallsicherheit und Wartbarkeit gewährleisten.
- Zudem wird eine modulare, kettenspezifische Modellierung vorgeschlagen, um Transparenz für und Anpassbarkeit durch den Nutzer sowie Skalierbarkeit und Erweiterbarkeit zu ermöglichen. Eine zentrale, monolithische Wissensbasis<sup>27</sup> im Sinne einer, alle Ketten umfassenden Modellierung wäre hierfür nicht geeignet.

## 6.2 Kriterien zur Methodenauswahl

Gemäß obiger Zielsetzung (Abschnitt 6.1) wurden mögliche Modellierungsarten und Methoden vorausgewählt sowie anhand folgender, zusätzlicher Kriterien miteinander verglichen:

### a) *Tauglichkeit und Konzeptbezug:*

Eine Schätzung der Kettenleistung sollte auch bei *unsicherem, ungenauem Expertenwissen* und *unpräzisen oder veralteten Eingangsdaten* (wie Wettervorhersagen oder Karten) möglich sein.

Ein *normierter Wertebereich* [-1.0 ; 1,0] oder [0.0 ; 1.0] würde hierbei die anschließende *multikriterielle Bewertung* und Auswahl von Ketten vereinfachen.

### b) *Transparenz & Introspektion:*

Die Modellierung soll vom Menschen leicht verstanden, interpretierbar und anpassbar sein. Eine transparente und verständliche Darstellung ist daher einer impliziten Wissensbasis (Blackbox, „erlerntes“ Programm) vorzuziehen.

### c) *Integration & Skalierbarkeit:*

Die Modellierung soll erweiterbar, skalierbar und wartbar sein. Dies umfasst sowohl die Integration auf unterschiedlichen Sensor-/Trägerplattformen sowie die Anpassung für neue Einsatzräume beispielsweise neue aufgabenspezifische Ketten, neue Umgebungen bzw. Terrain.

Die Auswertung der Kettenmodelle muss echtzeitfähig sein und nur einen geringen zusätzlichen Rechenaufwand nach sich ziehen.

Zur prototypischen Umsetzung und Evaluierung des Konzeptes wären fertige APIs/Werkzeuge (COTS-Lösungen) und Methoden, die mit kleinen/mittleren Trainings- und Testdatenbanken einsetzbar sind, wünschenswert.

### d) *Rückschlüsse & Verbesserungsvorschläge:*

Aus der Modellauswertung generierte Sensor- und Plattformzustandsänderungen sind im Konzept explizit vorgesehen. Die gewählte Modellierungsmethode soll daher sowohl vorwärts als auch rückwärts auswertbar sein, um Rückschlüsse von der Wirkung auf die Ursache zu ermöglichen (engl. *Forward and Backward Reasoning* [RuNo20, ThBF05]).

---

<sup>27</sup> Alle Informationen und Daten wären in einer einzigen Struktur gespeichert und miteinander verknüpft. Monolithische Wissensbasen können in vielen Anwendungen nützlich sein, sind jedoch auch schwer zu aktualisieren, zu erweitern oder anzupassen.

### 6.3 Vergleich und Auswahl einer Methode

Gemäß folgender Quellen [BeKe19, Erte16a, GiRi05, KACH15, Pupp90, Reif00, RuNo20], können in Frage kommende Methoden in die folgenden Kategorien eingeteilt werden:

**Regel-/Logikbasierte Methoden (RLM)** bieten eine intuitive und weit verbreitete Methode zur Wissenserhebung. Allerdings nimmt mit zunehmender Komplexität und Umfang der Aufgabe die Anzahl der hinterlegten Regeln in der Wissensbasis zu. Die Prüfung auf Korrektheit, Vollständigkeit und das Ausschließen von gegenseitig widersprechenden Regeln gestalten sich bei komplexen Aufgaben schwierig. Darüber hinaus kann in traditionellen regel- und logikbasierten Ansätzen kein implizites oder probabilistisches Wissen hinterlegt werden, weshalb keine automatischen Schlussfolgerungen (Inferenz) für unbekannte Fälle oder Zustände gezogen werden können. Daher müssen sämtliche Zustände und Fälle explizit abgebildet werden, was bei komplexen Systemen zu Problemen bezüglich des Aufwands und der Vollständigkeit führen kann.

Andererseits existieren ausgezeichnete Werkzeuge z.B. für die Modellierung und Prüfung von Zustandsautomaten, Petri-Netzen und Entscheidungsbäumen, die einen graphischen Entwurf und eine Wartung vereinfachen. Aufgrund ihrer deterministischen Eigenschaften eignen sich RLMs zur Abbildung sicherheitsrelevanter Systeme und Anlagen, da sowohl Korrektheit und Widerspruchsfreiheit (theoretisch) überprüfbar und nachweisbar sind.

Relationale, hierarchische Wissensrepräsentationen beispielsweise in Form von **Ontologien** können eingesetzt werden, um die Fähigkeiten und Ressourcen von Plattformen, Sensoren sowie deren Verarbeitung und Einsatz zu modellieren [CHLN09]. So nutzt das *Missions and Means Framework* (Abb. 21) Ontologien auf der Ebene des Ressourcenmanagements (Abschnitt 3.1.2) zur statischen Fähigkeitsanalyse und zur missionsoptimalen Auswahl von Trägerplattformen und geeigneten Sensoren innerhalb großer C2-Netzwerke.

Ontologien sind jedoch auch für das Ressourcenmanagement auf der Plattform selbst geeignet, wie von [Smir18] gezeigt. Hierbei wurde die Modellierung und Auswahl sensorischer und perzeptiver Fähigkeiten in Abhängigkeit von technischen Komponenten bzw. Ressourcen (Missionsrechner, Gimbal) für unbemannte Luftfahrzeuge im Rahmen simulierter Aufklärungsmissionen erfolgreich umgesetzt.

Da Ontologien auf einer formalen, logischen Struktur basieren, können sie meist nur exakte und klare Zusammenhänge darstellen. Bei der Modellierung realer Zusammenhänge, insbesondere in komplexen Systemen, können jedoch unscharfe oder unsichere Effekte auftreten, die nicht genau vorhersehbar oder messbar sind. Hier bieten probabilistische Methoden, wie beispielsweise Bayessche Netze, den Vorteil, dass sie mit Unsicherheiten und unvollständigen Informationen umgehen können und somit eine realitätsnähere Modellierung ermöglichen. Um den Nutzen der Vererbung auszuspielen zu können, ist zudem eine zentrale Wissensrepräsentation unumgänglich [Stuc09]. Dies steht im Widerspruch zum modularen Ansatz des Systemkonzeptes.

**CBR** (engl. *case based reasoning*, CBR) orientiert sich an den kognitiven Fähigkeiten des Menschen und bietet die Möglichkeit, das Wissen nicht in Form abstrakter, mathematischer Regelsätze, sondern anhand von Beispielfällen zu spezifizieren [Kolo14]. Durch Interpolation und Inferenz wird von dieser dedizierten Fallbasis auf ähnliche oder unbekannte Fälle geschlossen [RiSc13]. Konzeptbezogen könnten so Problemlösungen in Form von Sensor- und Algorithmen-konfigurationen automatisch generiert werden.

Aufgrund der hierfür notwendigen Interpolation und Inferenz wären die Lösungen aber gegebenenfalls auch fehleranfällig und schlecht überprüfbar. Ebenso ist die Skalierbarkeit und Erweiterbarkeit kritisch zu sehen, da die Fallbasis anhand neuer/geänderter Fälle aufwendig und schlecht nachvollziehbar erweitert oder korrigiert werden müsste. Zusätzlich erscheint CBR aufgrund der Forderung nach einem dezentralen Modellierungsansatz für einzelne Ketten und einer normierten, vergleichenden Bewertung weniger gut zur gesuchten Kettenmodellierung geeignet. CBR könnte sich jedoch als Erweiterung des Konzepts zur automatischen Feinjustierung von Ketten anbieten.

Bei **lernenden Verfahren** (LV) muss das Wissen nicht explizit formalisiert werden. Vielmehr wird das Systemverhalten anhand von Trainingsmengen gelernt. Metalearning kann hierbei prinzipiell zur Auswahl von Algorithmen [BRSV22a, Vans10] sowie zur Verbesserung eines Sets von Algorithmen (Ensembles) [BRSV22b] genutzt werden. Bei entsprechend großen Trainingssets können Algorithmen gezielt ausgewählt werden, jedoch müssen hierbei sämtliche Alternativen bereits beim Training bekannt sein. Dies würde sowohl der Erweiterbarkeit (neues Training) als auch dem Gedanken einer dezentralen Wissensbasis widersprechen. Ensemble-Methoden lernen dagegen "Metadaten" über die Performance der einzelnen Modelle innerhalb des Ensembles, um die Gewichtung der Modelle oder die Art der Kombination so anzupassen<sup>28</sup>, dass eine im Vergleich zu einem Modell höhere Vorhersagegenauigkeit erreicht wird.

In [Hell19] wird ein kombiniertes ML-Verfahren zur Funktionsapproximation beschrieben, mit dem sich Umwelt- und Plattformparameter direkt auf die Kettenleistung abbilden lassen. Hierfür wurde ein NEuro Fuzzy function apPROXimator (NEFPROX) zusammen mit einem CNN anhand von aus der virtuellen Simulation gewonnenen Daten trainiert und für die Kettenauswahl eingesetzt. Ein Vorteil dieser Methode liegt in der Fähigkeit, mehrdimensionale, nichtlineare Zusammenhänge zu erlernen, die möglicherweise von Experten nur ungenau oder unvollständig beschreibbar wären. Zur Evaluierung der Modelle wurde der Sensoreinsatz und die Algorithmenwahl im Rahmen einer simulierten Aufklärungsmission erfolgreich demonstriert. Die Arbeit von [Hell19] bestätigt, dass LV sich besonders dann eignen, wenn Experten "intuitiv und aus dem Bauch heraus" entscheiden und sich Regeln bzw. Zusammenhänge aufgrund der (Szenarien-)/Komplexität schwer ableiten lassen.

Aufgrund mangelnder Transparenz und Erklärbarkeit des Verhaltens werden lernende Ansätze allerdings selten für sicherheitsrelevante Systeme eingesetzt. Zudem sind lernende Verfahren aufgrund des Aufwands für das Erstellen der benötigten Trainingsdaten kritisch zu hinterfragen. Da in dieser Arbeit die Evaluierung des SPMS-Konzepts anhand realer Flugversuche untersucht werden soll, können zudem aus der Simulation gewonnene Trainingsdaten nicht bzw. nur eingeschränkt genutzt werden. Folglich wären zusätzliche Flugversuche und eine zeit- und ressourcenaufwändige Annotation der Trainings- und Testdaten notwendig.

### **Entscheidungen unter Unschärfe und Unsicherheit**

Die vorherigen Ansätze beruhen zumeist auf deterministischen Entscheidungsmodellen und sind daher in der Regel auf sicheres Wissen und Fakten angewiesen<sup>29</sup>. Dies schließt einerseits

---

<sup>28</sup> Bagging, Boosting oder Stacking, sind Techniken des Machine Learning, bei denen mehrere Modelle zu einem Ensemble kombiniert werden.

<sup>29</sup> So wären sämtliche Annahmen und Schlüsse in Form von Regeln bzw. Ontologien zu hinterlegen oder durch Inferenz bzw. Vererbung schließend zu erweitern. Bei lernenden oder fallbasierten Ansätzen gestaltet sich eine

die Wissenserhebung als Wechselwirkung zwischen Ursache und Ergebnis ein und andererseits eine sichere und exakte Bestimmung des wahren Umweltzustandes. In der Realität existieren jedoch häufig nur schwer fassbare, unscharfe sowie nicht zuverlässig oder sicher beschreibbare Zustände und Zusammenhänge.

Während in der klassischen Logik Fakten nur als wahr oder falsch dargestellt und somit diskreten Mengen zugeordnet werden, erlaubt die **Fuzzy-Logik** Mengen ohne scharfe Grenzen. Dadurch kann ein Element "zu einem bestimmten Grad" einer Menge angehören. Dieser Grad der Zugehörigkeit wird durch einen Wert aus dem Intervall  $[0,1]$  angegeben und durch die jeweilige Zugehörigkeitsfunktion beschrieben. Mithilfe von problembezogenen Verläufen, wie trapezförmigen oder gaussverteilten Funktionen, lassen sich auch unscharfe Begriffe aus dem natürlichen Sprachgebrauch, wie "heiß", "kalt", "groß" oder "klein", darstellen. Die Erweiterung der Logik um die unscharfe Mengentheorie ermöglicht daher auch den Einsatz in partiell beobachtbaren oder stochastischen Umgebungen.

Allerdings geht damit häufig ein Verlust an Verständlichkeit einher, da der Prozess der unscharfen Modellierung nicht immer eindeutig ist. Zudem gibt es innerhalb der Logik keine vollständige Lösung. "Systemdesigner müssen daher sorgfältig abwägen, wie detailliert sie ihr Modell spezifizieren möchten und welche Details sie auslassen möchten" [RuNo20]. Das Hinzufügen neuer Regeln ist zwar intuitiv und einfach, jedoch steigt damit nicht nur die Genauigkeit der Modellierung, sondern auch deren Komplexität, was möglicherweise die Korrektheit und Widerspruchsfreiheit beeinträchtigt. Zusätzlich nimmt die benötigte Zeit zur Ableitung und Auswertung aller Regeln zu. Obwohl Heuristiken<sup>30</sup> die Such- und Verarbeitungsprozesse beschleunigen können, lässt sich die Anzahl möglicher Widersprüche bei abgeleiteten neuen Regeln nicht reduzieren

Mit Hilfe **Probabilistischer Methoden** (PM) können Vorhersagen und Entscheidungen auch unter Unsicherheit/Ungewissheit getroffen werden, indem Wahrscheinlichkeiten oder Glaubensmaße modelliert und in Form von Graphen verständlich dargestellt werden. Im Vergleich zu bisherigen Methoden gelingt eine Modellierung vager Hypothesen daher häufig ausdrückstärker/präziser und für den Menschen nachvollziehbar [Hüb13, SDLC93]. Zur Kettenmodellierung könnten sich Bayessche Netze, Markov Ketten oder die Dempster-Shafer Evidenztheorie eignen.

Sowohl Bayes-Netze als Markov-Modelle verbinden die Wahrscheinlichkeitstheorie mit der Graphentheorie [KBBK15a], wodurch sich eine intuitive Möglichkeit bietet, um das Domänenwissen von Experten abzubilden. **Markov-Ketten** können als stochastische Zustandsautomaten aufgefasst werden, wobei die Zustandsübergänge als Wahrscheinlichkeiten modelliert werden. Sie eignen sich sehr gut, um dynamische Prozesse wie Warteschlangen oder Prozessabläufe abzubilden [RuNo20].

**Bayessche Netze** (BN) erweitern die Modellierungsmöglichkeiten von Markov-Ketten, indem einerseits die bedingte Unabhängigkeit von Zuständen gefordert wird und darüber hinaus eine kausale Richtung vorgegeben wird. Es dürfen somit keine Schleifen auftreten, was sich in der

---

Generalisierung auf mögliche aber gegebenenfalls unwahrscheinliche Umwelt-/Sensorconstellation aufgrund des Umfangs der Trainingssätze als schwierig.

<sup>30</sup> Dies sind Annahmen, die die Kosten nie überschätzen dürfen, z.B. Luftlinie zur Abschätzung der kürzesten Strecke.

Netzwerktopologie eines azyklischen gerichteten Graphen widerspiegelt. Dank der so dargestellten Un-/Abhängigkeiten kann eine effiziente Berechnung [Dörn18, Papu16] durchgeführt werden. Zudem kann die Richtung des Schlussfolgerns umgekehrt<sup>31</sup> werden und sowohl die Netzstruktur als auch die in den Knoten hinterlegten Wahrscheinlichkeitstabellen können aus Trainingsdaten gelernt werden [KACH15].

Der "Zwang" zu Unabhängigkeitsannahmen (Diskretisierung<sup>32</sup>) ist bei der Modellierung von komplexen, realen Systemen möglicherweise nicht immer zutreffend, wodurch die tatsächlichen Abhängigkeiten zwischen Variablen möglicherweise nicht genau erfasst werden. Daneben können die Ergebnisse durch Subjektivität bzw. Voreingenommenheit negativ beeinflusst werden. Beides, Diskretisierung und Subjektivität, können zu einem möglichen Informationsverlust und zu einer reduzierten Modellgenauigkeit führen [FiTh07].

Die **Dempster-Shafer Evidenztheorie** (DSE) gilt als Erweiterung der klassischen Wahrscheinlichkeitstheorie und ermöglicht neben dem Schließen unter Risiko auch das Schließen unter Ungewissheit [YaLi08]. Mit Hilfe der DS-Kombinationsregel (orthogonale Summe, könnte zudem das Wissen aus unabhängigen Quellen zusammengefasst werden, um so die Unwissenheit zu reduzieren [BeKe19]. Auf die Aufgabenstellung übertragen, könnte das Wissen unterschiedlichen Experten (Entwickler, Tester, Anwender) separat modelliert und anschließend fusioniert werden, wie von [HoSc15] im Rahmen von Pilotenversuchen untersucht. DS war ein sehr innovatives, vielversprechendes Forschungsfeld. Es fehlen jedoch weiterhin Werkzeuge, die für eine schnelle Umsetzung nötig wären. Des Weiteren existieren noch systematische Probleme. So können durch Lücken in der Glaubensmodellierung nicht entscheidbare Konstellationen auftreten und durch DS prognostizierte Ergebnisse können von den Erwartungen menschlicher Beobachter abweichen. Da zudem der Rechenaufwand exponentiell ansteigt und die Modellierung nicht durch graphische Abhängigkeiten vereinfacht werden kann, wird DS nicht weiterverfolgt.

Die abschließende Zusammenfassung in Tabelle 1 greift die relevanten Modellierungskriterien aus Abschnitt 6.2 auf. Sie schließt obige Erläuterungen ein und basiert zusätzlich auf einer sorgfältigen Recherche und Analyse der Sekundärliteratur [Bmwi21, Erte16a, KBBK15b, RuNo20]. In der Tabelle werden darüber hinaus neben den genannten konzeptionellen Anforderungen die wissenschaftliche Aktualität der Methode sowie der Aufwand für eine prototypische Implementierung abgeschätzt.

Wie sich aus der Tabelle ablesen lässt, wären Lernende Verfahren, CBR und Entscheidungen unter Unsicherheit hinsichtlich einer möglichen Modellierung vielversprechende Verfahren. BNs können unsichere System- und Umweltzustände abbilden, liegen in einem normierten Bereich [0-1], was Vorteile für den Ketten-Vergleich mit sich bringt, bieten eine gute Verständlichkeit (Graphenmodelle) und könnten auch zur Generierung navigatorischer Hinweise genutzt werden. Nach Abwägung der Vorzüge und Defizite obiger Methoden (Kriterien in Abschnitt 6.2), soll im Weiteren eine Modellierung daher BNs zur Implementierung der prototypischen Umsetzung des Systemkonzeptes untersucht, umgesetzt und bewertet werden.

---

<sup>31</sup> Entsprechend dem SPMS-Konzept sollen aus Modellen Verbesserungsvorschlägen generiert werden können.

<sup>32</sup> Kontinuierliche Variablen müssen diskretisiert werden, bevor sie in das BN-Modell integriert werden können.



Daher werden in den folgenden Unterkapiteln zunächst die Grundlagen von BNs ausführlich dargestellt, worauf aufbauend anhand von Kettenbeispielen eine beispielhafte Modellierung von Sensor- und Wahrnehmungsketten stattfindet.

**Tabelle 1:** Anforderungstabelle für die Auswahl einer Methode zur Kettenmodellierung.

Anforderungen Methode	konzept- tauglich	verständlich transparent	erweiterbar	rückschluss- fähig	aktuell	aufwändig
<b>RLM</b>	<b>0</b>	<b>0</b>	+	-	-	++
<b>Ontologien</b>	<b>0</b>	-	<b>0</b>	+	+	-
<b>Lernende Verfahren</b>	++	--	<b>0</b>	<b>0</b>	++	-
<b>Fallbasiertes Lösen</b>	-	++	-	+	<b>0</b>	-
<b>Entscheidungen unter Unsicherheit/Unschärfe</b>						
<b>Fuzzy-Logic</b>	<b>0</b>	-	<b>0</b>	--	<b>0</b>	<b>0</b>
<b>Markov Ketten</b>	+	+	<b>0</b>	+	<b>0</b>	<b>0</b>
<b>Bayessche Netze</b>	++	+	+	+	+	+
<b>Dempster-Shafer</b>	++	<b>0</b>	-	<b>0</b>	++	<b>0</b>

## 6.4 Grundlagen Bayesscher Netze

Bayessche Netze sind „Graphische Modelle“ (engl. *graphical models*, GM), die sich aus der Vereinigung der Methoden der Graphentheorie und der klassischen Wahrscheinlichkeitstheorie ableiten lassen. GMs repräsentieren dabei eine einheitliche Herangehensweise, die neben der Beschreibung von BNs u.a. auch Markov Modelle und Markov Random Fields einschließt. Maßgeblichen Anteil hatten dabei die Arbeiten von Pearl [Pear09, Pear88], Lauritzen [Laur96, SDLC93] und Jordan [Jord98, WaJo08].

Die grundlegende Begriffe und Berechnungsvorschriften der Wahrscheinlichkeits- sowie Graphentheorie können ausführlich in den folgenden Quellen [Dörn18, Erte16b, KBBK15a, Papu16, RuNo20] nachgeschlagen werden und werden daher vorgezogen.

### 6.4.1 Theorie und Aufbau

Für eine *vollständige Wahrscheinlichkeitsverteilung* müssten sämtliche Wahrscheinlichkeiten für alle möglichen Wertetupel einer Menge von Zufallsvariablen  $X_1, \dots, X_n$  hinterlegt werden. Bereits für ein 3-dimensionales Problem mit den binären Aussagen  $X_1, \dots, X_n$  umfasst die gemeinsame Wahrscheinlichkeitsverteilung  $2^3 = 8$  Werte:

$$\begin{aligned}
 &P(X_1, X_2, X_3), & P(X_1, X_2, \overline{X_3}), & P(X_1, \overline{X_2}, X_3), & P(\overline{X_1}, X_2, X_3) & \quad (\text{F. 1}) \\
 &P(X_1, \overline{X_2}, \overline{X_3}), & P(\overline{X_1}, X_2, \overline{X_3}), & P(\overline{X_1}, \overline{X_2}, X_3), & P(\overline{X_1}, \overline{X_2}, \overline{X_3})
 \end{aligned}$$

Mit Hilfe dieser Verbundwahrscheinlichkeitsverteilung lassen sich Abfragen beantworten, da sowohl die Randwahrscheinlichkeiten als auch die bedingten Wahrscheinlichkeiten berechnet werden können. Im Beispiel führt die Aufsummierung der Wahrscheinlichkeiten (*Marginalisierung*) und die Umstellung mit Hilfe der *Kettenregel* zu:

$$P(X_1) = P(X_1, X_2, X_3) + P(X_1, X_2, \overline{X_3}) + P(X_1, \overline{X_2}, X_3) + P(X_1, \overline{X_2}, \overline{X_3})$$

$$P(X_3 | X_1, X_2) = \frac{P(X_1, X_2, X_3)}{P(X_1, X_2)} = \frac{P(X_1, X_2, X_3)}{P(X_1, X_2, X_3) + P(X_1, X_2, \overline{X_3})}$$

Im Allgemeinen ist diese Wahrscheinlichkeitsverteilung jedoch zu komplex. So würden sich für eine Aufgabenstellung, die durch  $n$  binäre Aussagen beschrieben wird,  $2^n$  Werte für die Verbundwahrscheinlichkeiten ergeben. Dies führt i.d.R. zu einer Reihe von Problemen:

- Exponentieller Speicheraufwand zur Speicherung der Wahrscheinlichkeitsverteilung.
- Exponentieller Rechenaufwand zur Berechnung von Rand- und bedingten Wahrscheinlichkeiten.

Die Bestimmung aller Werte der Wahrscheinlichkeitsverteilung ist daher bei komplexen Zusammenhängen (großen BNs) aufwendig und häufig unter Echtzeitanforderungen nicht möglich.


Allerdings kann die *vollständige Wahrscheinlichkeitsverteilung* durch Unabhängigkeiten zwischen einzelnen Zufallsvariablen in kleinere gemeinsame Verteilungen in Form *lokaler Wahrscheinlichkeitsverteilungen* unterteilt werden. Derartige Vereinfachungen können gezielt bei der Modellierung von Anwendungs- und Expertenwissen eingebracht werden. So setzen BNs auf eine graphische Darstellung von bedingten Wahrscheinlichkeiten (d-Separierung, Abb. 29), indem *stochastische und bedingte Unabhängigkeiten* in der Struktur des Graphen abgebildet und später zur Berechnung herangezogen werden.

*Bayes-Netze* sind daher gerichtete, anti-zyklische Graphen, deren Knoten Zufallsvariablen (Aussagen) und deren Kanten die stochastischen Abhängigkeiten zwischen den Aussagen darstellen:

- Die *Aussagen* können Hypothesen, Wahrscheinlichkeitsfunktionen oder Zustandsgrößen widerspiegeln.
- *Kausalität* im Sinne einer Abhängigkeit zwischen Ursache (Fehler) und Wirkung (Symptom) wird durch die Vorgabe einer Kantenrichtung zwischen Eltern- und Kindknoten erreicht.
- *Unabhängigkeit* zwischen einzelnen Aussagen wird durch fehlende Verbindungen modelliert.

Die Netzwerkstruktur ergibt sich aus den in Abb. 29 dargestellten topologischen Grundelementen. Für so verschaltete Knoten hängt der Zustand einzelner Knoten eines BNs von ihren Vorgängern bzw. Nachfolgern ab. Hierbei spricht man von aktivierten Knoten oder aktiven Verkettung. Allerdings können Knoten durch Hinzunahme von Beobachtungen bzw. Informationen über einen anderen Knoten voneinander bedingt unabhängig und somit blockierend im Sinne einer bedingten Unabhängigkeit werden. Dieser Formalismus wird als d-

Separation bezeichnet. Zur weiteren Erklärung werden die Grundelemente Bayesscher Netze nach Abb. 29 wie folgt erläutert.



**Abb. 29:** Grundelemente eines BN: serielle, konvergente und divergente Verbindung. Je nach Vorgabe Evidenz kann es zu einer d-Separation im Sinne durch  $Z$  blockierter Knoten  $X, Y$  kommen.

Die *serielle Verbindung* (a) wird auch als kausale Kette bezeichnet. Hier löst die Ursache  $X$  das Ereignis  $Z$  aus, welches wiederum das Ereignis  $Y$  verursacht. Bei Vorgabe von  $Z$  (harte Evidenz) ist in dieser Wirkungskette das Ereignis  $Y$  vom Ereignis  $X$  bedingt unabhängig und somit  $X, Y$  durch  $Z$  blockiert.


Die *konvergente Verbindung* (b) gibt eine gemeinsame Wirkung wieder. Die beiden unabhängigen Ursachen  $X$  und  $Y$  lösen das Ereignis  $Z$  aus. Hierbei darf nichts über den Knoten  $Z$  oder seine Kinder  $K$  bekannt sein. Evidenz von  $X$  oder  $Y$  hat folglich keinerlei Einfluss auf die Wahrscheinlichkeit des anderen Elternknotens. Falls jedoch die Wahrscheinlichkeit von  $Z$  oder eines Kindes  $K$  beobachtet wird, so kann Evidenz über einen Elternknoten Auswirkungen auf die anderen Elternknoten haben. Dieser Sonderfall „*explaining away*“ wird in Abb. 31 ausführlicher betrachtet.

Die *divergente Verbindung* (c) beschreibt eine gemeinsame Ursache. Ein Ereignis  $Z$  ist gemeinsame Ursache für die beiden unabhängigen Ereignisse  $X$  und  $Y$ . Im Fall von harter Evidenz für  $Z$  wird die Unabhängigkeit von  $X$  und  $Y$  aufgehoben<sup>33</sup> und die Knoten können sich gegenseitig beeinflussen.

## 6.4.2 Beispielnetz zur Verdeutlichung

Die weiteren Herleitungen werden anhand eines repräsentativen Beispielnetzes mit acht Knoten (Abb. 30) erläutert. Die Knoten  $X_1$  und  $X_2$  sind hier die Evidenzen (Beobachtungen) mit den Apriori-Wahrscheinlichkeiten  $P(X_1)$ ,  $P(X_2)$ , da diese Knoten keine Vorgänger haben. Wie anhand der Inferenzmöglichkeiten aus Abb. 31 ersichtlich, handelt es sich um ein BN zur Prognose in kausaler Richtung.

<sup>33</sup> Zur Verdeutlichung dient das Beispiel aus [Barr07], das den Zusammenhang zwischen Geschlecht, der Haarlänge und der Körpergröße dargestellt: „*Kennt man eine Person nicht, hat die Haarlänge einen Einfluss auf die Wahrscheinlichkeit über das Geschlecht der Person. Und diese wiederum auf die geschätzte Körpergröße. Ist allerdings bekannt, dass es sich bei der Person um einen Mann handelt, kann man aus der Länge der Haare keine Rückschlüsse auf die Größe der Person ziehen*“.



$$BN = (X, E, P)$$

- $X$ : endliche Menge Zufallsvariablen (Aussagen)
- $E$ : Kantenmenge zu Beschreibung der Abhängigkeiten
- $P$ : bedingte Wahrscheinlichkeitsverteilung für jeden Knoten  $P(X_i | \text{Eltern}(X_i))$

**Abb. 30:** Bayessches Netz als DAG (engl. *directed acyclic graph*): Beispielnetz mit 8 Knoten aus [Dörn18].

Aus der allgemeinen Kettenregel [Papu16] ergibt sich für die Menge der *Eltern* ( $X_i$ ) eines Knotens  $X_i$  die Verbundwahrscheinlichkeitsverteilung  $P(X_1, \dots, X_n)$  des BNs:

$$P(X_1, \dots, X_n) = \prod_{i=1}^n P(X_i | X_1, \dots, X_{i-1}) = \prod_{i=1}^n P(X_i | \text{Eltern}(X_i)) \quad (\text{F. 2})$$

$P(X_i | \text{Eltern}(X_i))$  ist dabei die bedingte Wahrscheinlichkeitsverteilung eines Knotens  $X_i$  gegeben seine *Eltern* ( $X_i$ ). Aus (F. 2) lässt sich die lokal strukturierende Eigenschaft ableiten:

$$P(X_i | X_1, \dots, X_{i-1}) = P(X_i | \text{Eltern}(X_i)) \quad (\text{F. 3})$$

Sie impliziert, dass jeder Knoten  $X_i$  bei bekannten *Eltern* ( $X_i$ ) bedingt unabhängig von seinen restlichen Vorgängern in der Knotenreihenfolge sein muss. BNs gehören so zur Klasse der *lokal strukturierten Systeme*. In solchen auch als „schwach besetzt“ bezeichneten Systemen interagiert jede Komponente nur mit einer beschränkten Zahl anderer Komponenten, unabhängig von der Gesamtzahl der Komponenten. Im Gegensatz zur *vollständigen Wahrscheinlichkeitsverteilung* folgt daher anstatt eines exponentiellen ein lineares Komplexitätswachstum, da nur noch  $n$  bedingte Wahrscheinlichkeiten  $P(X_i | \text{Eltern}(X_i))$  gespeichert werden müssen [RuNo20].

Im Beispielnetz aus Abb. 30 ergibt sich folgende Verbundwahrscheinlichkeit, wobei jeder Knoten von allen nicht unmittelbaren Vorgängerknoten bedingt/stochastisch unabhängig ist:

$$\begin{aligned} P(X_1, X_2, X_3, X_4, X_5, X_6, X_7, X_8) \\ = P(X_1) \cdot P(X_2) \cdot P(X_3 | X_1, X_2) \cdot P(X_4 | X_3) \cdot P(X_5 | X_3) \\ \cdot P(X_6 | X_3, X_4, X_5) \cdot P(X_7 | X_2, X_6) \cdot P(X_8 | X_4, X_6) \end{aligned} \quad (\text{F. 4})$$

Durch die kompakte Darstellung mit Hilfe von BNs kann also die Komplexität<sup>34</sup> deutlich reduziert und Speicherbedarf und Rechenaufwand gesenkt werden.

Für die Anwendung von BNs können drei Problemfälle unterschieden werden [Dörn18]:

<sup>34</sup> u.a. aufwendige und fehleranfällige Ermittlung sämtlicher Wahrscheinlichkeiten (F. 1)

- a) *Aufstellen*  
 Gegeben: Verbale Problembeschreibung, Wahrscheinlichkeiten  $P$   
 Gesucht:  $BN = (X, E, P)$
- b) *Lernen*  
 Gegeben: Datensatz  $D$   
 Gesucht:  $BN = (X, E, P)$
- c) *Wissensverarbeitung (Schließen / Inferenz)*  
 Gegeben:  $BN = (X, E, P)$ , Evidenzen  $X_E$ , gesuchte Aussage/Größe  $X^*$   
 Gesucht: a-posteriori Wahrscheinlichkeiten  $P(X^* | X_E)$

Beim Aufstellen von BNs werden zunächst die erforderlichen Zustandsvariablen und ihre Abhängigkeiten aus der Problemstellung bestimmt. Anschließend erfolgt die Festlegung der Struktur des Bayesschen Netzes mithilfe von Domänen- bzw. Expertenwissen und der Auswertung von Beispieldaten. Die einzelnen Knoten werden dann schrittweise um die benötigten Wahrscheinlichkeiten erweitert.

Folgende Vorgehensweise wurde in den Arbeiten von Pearl [Pear88] erstmals zusammengefasst und hat sich zum Aufstellen von BNs bewährt [RuNo20]:

1. Bestimmung der *Knoten*  $\{X_1, \dots, X_n\}$ :  
 Bestimmung der Menge der zur Problemstellung erforderlichen Zufallsvariablen und Sortierung nach der kausalen Reihenfolge, sodass die Ursache vor der Wirkung liegt.
2. Bestimmung der *Verknüpfungen* für  $i = 1$  bis  $n$ :
  - a. Für alle Zufallsvariablen  $X_i$  aus der Menge  $\{X_1, \dots, X_n\}$  wird eine minimale Menge von Eltern für  $X_i$  ausgewählt („direkt abhängigen“), so dass jeder Knoten  $X_i$  bei bekannten *Eltern*( $X_i$ ) bedingt unabhängig von seinen restlichen Vorgängern in der Knotenreihenfolge ist (F. 3):

$$P(X_i | X_1, \dots, X_{i-1}) = P(X_i | \text{Eltern}(X_i))$$

- b. Füge für jedes übergeordnetes Element eine gerichtete Kante zu  $X_i$  ein.
3. Vorgabe der bedingten *Wahrscheinlichkeiten*:  
 Für alle Variablen  $X_i$  des Netzes sind die bedingten Wahrscheinlichkeiten  $P(X_i | \text{Eltern}(X_i))$  empirisch aus Erfahrungswerten oder Statistiken zu bestimmen. Die bedingte Wahrscheinlichkeitsverteilung einer Zufallsvariable, bei gegebenen Zufallsvariablen an den Elternknoten wird in Form von Wahrscheinlichkeitstabellen (engl. *conditional probability table*, CPT) des Knotens  $X_i$  angegeben.

## 6.5 Konzeptionelle Eigenschaften Bayesscher Netz

Beim Aufstellen von BNs muss ein Kompromiss zwischen „Genauigkeit und Generalisierungsfähigkeit“ und „Komplexität und Aufwand“ gefunden werden.

Hierfür gilt es, Prinzipien und Regeln zu beachten, die Möglichkeiten zu nutzen und die Modellierung anhand von Testdaten schrittweise zu aktualisieren.

### 6.5.1 Prinzipien und Regeln

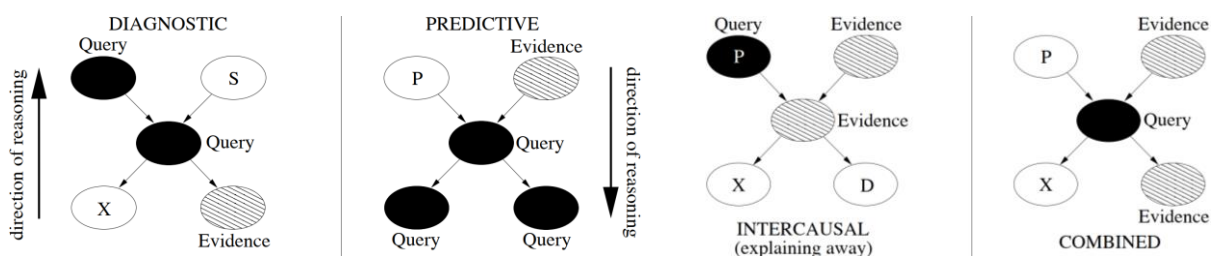
Eine ungünstige Sortierung der Knotenreihenfolge führt zu zusätzlichen und gegebenenfalls schwachen Verbindungen, deren Wahrscheinlichkeitsverteilungen häufig unnatürlich und daher schwierig bestimmbar sind. Für diese schwachen Abhängigkeiten, muss entschieden werden, ob neue Verknüpfungen eingefügt werden oder nicht, d.h. ob eine geringfügig erhöhte Aussagestärke oder Genauigkeit der Modellierung eine zusätzliche Komplexität des Netzes rechtfertigt. Diese Entscheidung ist domänen- bzw. problemspezifisch und muss anhand des jeweiligen Anwendungsfalles entschieden werden.

Nach [Erte16a] hängt die Topologie eines BN von der gewählten Variablenreihenfolge ab. Hierbei gilt, dass eine kausale Reihenfolge der Knoten zu kompakteren Netzen führt als eine diagnostische Reihenfolge. Diese Präferenzordnung ist auch bei der Wissenserhebung durch Experten zu beobachten [KSST82]: Ärzte ziehen es oft vor, zuverlässige Prognoseregeln für den Verlauf von Krankheiten zu erstellen, anstatt die schwierigere Aufgabe der Diagnose anhand von Symptomen zu den spezifischen Krankheiten durchzuführen..

### 6.5.2 Inferenz- und Schlussfolgerungsmöglichkeiten

Neben der strukturierten und kompakten Darstellung des Experten- oder Domänenwissen dienen BNs zum *Verarbeiten* des so hinterlegten Wissens. Dies wird als *Inferenz*, Schlussfolgern oder Schließen bezeichnet und ermöglicht die Berechnung der a-posteriori-Wahrscheinlichkeitsverteilung für eine Menge gesuchter Abfragevariablen  $X^*$  (engl. *query*).

Aus der Wahl der Beobachtungen, also durch Vorgabe der Evidenzvariablen  $X_E$ , ergibt sich Richtung der Inferenz. Gemäß Abb. 31 ergeben sich vier unterschiedliche Inferenzmöglichkeiten: kausale, diagnostische, interkausale und kombinierte Schlussfolgerung.



**Abb. 31** Grundsätzlichen Möglichkeiten der Inferenz (Schlussfolgern) mit Hilfe von BNs aus [KoNi10]. Durch Vorgabe der Beobachtung (*evidence*) kann die Richtung der Inferenz entweder diagnostisch, kausal (*predictive*), interkausal („*explaining away*“) oder kombiniert sein. Letztere kann durch Vorgabe mehrerer Evidenzen auftreten, wodurch inverse Abhängigkeiten entgegen der kausalen Richtung „erzwungen“ werden.

*Kausales Schließen* erfolgt über die Marginalisierung aller Ereignisse [Papu16], indem die Summierung über alle Knoten aus der Menge der  $Eltern(X_i) = \{X_{j_1}, \dots, X_{j_k}\}$  erfolgt:

$$P(X_i) = \sum_{X_{j_1}, \dots, X_{j_k}} P(X_{j_1}, \dots, X_{j_k}, X_i) \quad (\text{F. 5})$$

### 6.5.3 Berechenbarkeit und Komplexität

Obige Abfragen können mithilfe von (F. 2) in Summen von Produkten bedingter Wahrscheinlichkeiten überführt werden. Dies soll am Beispiel der seriellen und konvergente Verbindung für binäre Zufallszahlen verdeutlicht werden:

Serielle Verbindung (Abb. 29, a):

$$P(Y) = \sum_{X,Z \in \{0,1\}} P(X,Z,Y) = \sum_{X,Z \in \{0,1\}} P(X) \cdot P(Z|X) \cdot P(Y|Z)$$

Konvergente Verbindung (Abb. 29, b):

$$P(Z) = \sum_{X,Y \in \{0,1\}} P(X,Z,Y) = \sum_{X,Y \in \{0,1\}} P(X) \cdot P(Y) \cdot P(Z|X,Y)$$

Zur Berechnung der *diagnostischen Inferenz*, lassen sich zudem aus der Gesamtknotenmenge  $X = X^* \cup X_E \cup X_I$  die nicht beobachtbaren, versteckten Zwischenvariablen  $X_I$  (engl. *hidden variables*) ableiten.

Die Herleitung erfolgt durch Umformung der Produktregel. Mit der Menge der Evidenzen  $X_{E_1}, \dots, X_{E_k}$  sowie der internen Knoten  $X_{I_1}, \dots, X_{I_l}$  kann die gesuchte bedingte Wahrscheinlichkeit durch Einsetzen der beobachteten Werte  $e_i$  und durch Marginalisierung über alle Wahrheitswertkombinationen von  $X_{I_i}$  berechnet werden:

$$P(X^*|X_E) = \frac{P(X^*, X_E)}{P(X_E)} = \alpha \cdot P(X^*, X_E) = \alpha \cdot \sum_{X_I} P(X^*, X_E, X_I) \quad (\text{F. 6})$$

$$P(X^*|X_E) = \alpha \cdot \sum_{X_{I_1}, \dots, X_{I_l}} P(X^*, X_{E_1} = e_1, \dots, X_{E_k} = e_k, X_{I_1}, \dots, X_{I_l}) \quad (\text{F. 7})$$

Die Hilfsvariable  $\alpha = \frac{1}{P(X_E)}$  kann hierbei als Normierungsfaktor aufgefasst werden, um die Verbundwahrscheinlichkeiten in den Wertebereich  $\{0, 1\}$  einzupassen.

Wie sich anhand dieser Berechnungen andeutet, ist die Inferenz mittels BNs zunächst ein NP-hartes Problem: Bei ungünstiger Problemstellung und einer mehrfach verbundenen Netzstruktur kann die Komplexität für ein Netz mit  $b$  booleschen Variablen auf  $O(n \cdot 2^n)$  ansteigen [RuNo20].

Um das Problem der Komplexität beim *Schlussfolgerung durch Auszählen* von (F. 7) zu verbessern, existieren grundsätzlich mehrere Möglichkeiten [CDLS07, RuNo20]:

- a) *Exakte Inferenz* schließt arithmetische und algorithmische Verbesserungen ein, die zwar die Komplexität, den Speicherverbrauch verringern sowie Laufzeit verkürzen, jedoch die Genauigkeit nicht einschränken.

- b) *Stochastische Inferenz* wird benötigt, wenn aufgrund großer oder mehrfachverbundener Netze die Komplexität trotz der in a) beschriebenen Möglichkeiten nicht mehr handhabbar erscheint. Die Grundidee ist dabei, möglichst viele Simulationsläufe mit Zufallszahlen (Stichproben) durchzuführen und daraus die relevanten Häufigkeiten abzuschätzen. Mit der Zahl der Durchläufe verbessert sich zwar die Approximation, wobei jedoch nicht die Genauigkeit der exakten Inferenz (a) erreicht werden kann.

Die Möglichkeiten a) und b) sind in kommerziellen und teilweise frei verfügbaren Anwendungsprogrammen oder APIs für BNs als „*Solver*“ integriert und müssen nur noch auf die jeweilige Applikation angepasst werden.

#### 6.5.4 Lernfähigkeit

Bei vorhandenen Trainingsdaten, wäre auch ein automatisches Aufstellen des BNs [NeOt04] möglich. Ein *Lernalgorithmus* könnte dabei prinzipiell sowohl Knoten und Verknüpfungen und somit die Struktur bzw. Topologie des BNs erzeugen sowie die bedingten Wahrscheinlichkeiten derart abschätzen<sup>35</sup>, dass die den Trainingsdaten zugrundeliegenden Annahmen bestmöglich repräsentiert werden. Dieses Struktur- und Parameterlernen von BNs stellt sich als ein NP-hartes Problem dar, dessen Komplexität mit wachsender Variablenzahl exponentiell steigt [Chic96]. Ab einer gewissen Problemgröße werden daher gerne heuristische Optimierungsverfahren eingesetzt werden [Barb12, Heck08, KACH15, NeOt04]. Um die Lernalgorithmen sinnvoll einsetzen zu können, werden umfangreiche und verlässliche Lerndaten über alle möglichen Ereignisse und Zustände benötigt.

Da ein manueller Entwurf des Graphen i.d.R. eine leichter nachvollziehbare und damit aktualisier- sowie erweiterbare Struktur ergibt, wird im Zuge der prototypischen Umsetzung des SPMS ein automatisches Erstellen von BNs zum Lernen der Modelle nicht weiterverfolgt.

### 6.6 Kettenmodellierung zur Leistungsbestimmung

Um einen automatisierten, situationsoptimalen Sensoreinsatz sowie dessen computergestützte Auswertung zu ermöglichen, soll die Leistung einzelner Ketten so modelliert werden, dass die zu erwartende Qualität der Ergebnisse von Ketten (Kettenleistung) in Abhängigkeit von Umgebungsparametern abgeschätzt werden kann.

#### 6.6.1 3-Phasen-Modellierungsprozess

Zur Einhaltung systemischer Anforderungen (Transparenz-Erklärbarkeit, Eingriffsmöglichkeit) soll bereits bei Erstellung der Wissensbasis neben dem Expertenwissen der Entwickler auch das Einsatzwissen von Payload-Operateuren (Anwender) sowie der Bildauswertern explizit genutzt werden. Wie sich aus dem Vergleich möglicher Modellierungs-methoden (Abschnitt 6.3) sowie in Gesprächen mit Experten<sup>36</sup> ergeben hat, stellt hierbei eine graphische Modellierung und eine Abschätzung von Zusammenhängen bzw. Einflüssen in Form von Wahrscheinlichkeiten eine

---

<sup>35</sup> Z.B. durch statistische Methoden wie dem Zählen von Häufigkeiten in den Trainingsdaten.

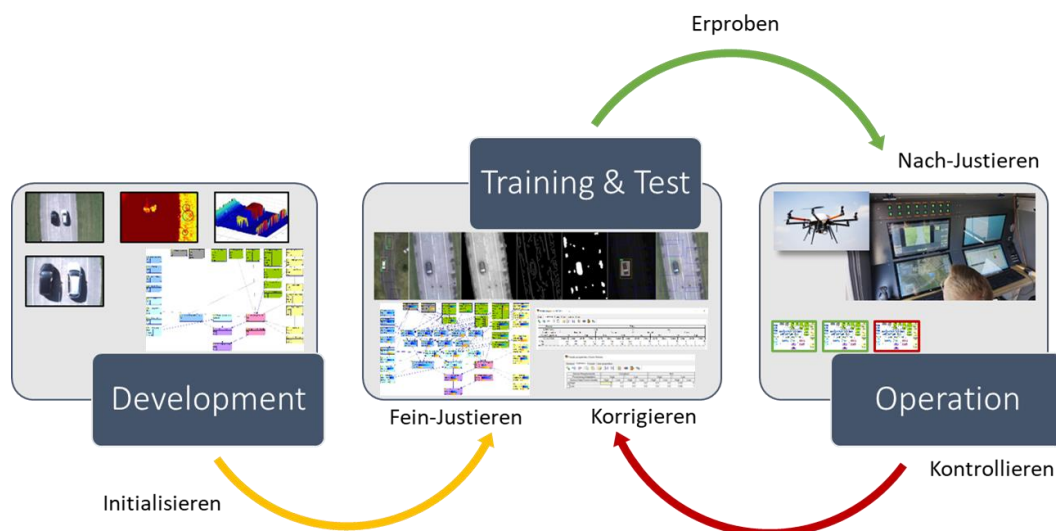
<sup>36</sup> Waffensystemunterstützungszentrum (WSU), Ausbildungszentrum für abbildende Aufklärung der Luftwaffe.



dem Menschen verständliche Form [Bmwi21] dar. Das Modellwissen zur Abschätzung der Tauglichkeit bzw. Einsetzbarkeit einzelnen Sensoren, Algorithmen oder ganzer Ketten könnte daher über einen mehrstufigen, iterativen Modellierungs- und Anpassungsprozess gemäß Abb. 32 sukzessive erweitert und verfeinert werden. Die Modellierung soll die folgenden Phasen durchlaufen:

- a) *In der Entwicklungs- und Initialisierungsphase* soll das Wissen der Entwickler über die prinzipielle Einsetzbarkeit, Anforderungen, Einschränkungen und Leistungsfähigkeit der gewählten Sensoren sowie der implementierten Methoden/Algorithmen genutzt werden. Hierdurch sollen erste Modelle über die erwartete Zuverlässigkeit einzelner Ketten und deren Ressourcenverbrauch erstellt werden.
- b) *In der Trainings- und Testphase* sollen diese Modelle angepasst, überprüft und gegebenenfalls nachgebessert werden. Das Ziel ist hierbei die Güte der Modellierung einzelner Ketten zu verbessern und den Vergleich mit anderen Ketten zu ermöglichen.
- c) *In der Erprobungsphase* sollen dem Anwender zudem Möglichkeiten zur Feinjustierung eingeräumt werden. Hierdurch sollen Anpassungen an aktuelle und gegebenenfalls in der Modellierung bisher nicht vorgesehene Gegebenheiten ermöglicht werden, indem unzureichende Modelle erneut die Trainings- und Testphase durchlaufen.

Neben der Evaluation der Ketten auf realen Flugdaten, wird auch ein Training- bzw. Test der Modelle unter reproduzierbaren Umweltbedingungen in synthetischen Sensor-Simulationsumgebungen verfolgt [CLHR14, DFRS19, KrRS20]. Die Vorteile einer Analyse in der Simulation ergeben sich durch die einfachen Variationsmöglichkeiten, die hohe Genauigkeit, die garantierte Reproduzierbarkeit in der Simulation sowie den geringeren Aufwand für das Erstellen synthetischer Trainings- und Testdaten [Krum23, LNSH23].



**Abb. 32:** Prinzipieller Ablauf zur Modellierung der Wahrnehmungsleistung bestehend aus Initialisierung, Training- & Test sowie Erprobung. Der Prozess ist an das 3-Phasen-Modellierungskonzept zur Abbildung von Expertenwissen [GoFH90, Pupp90] aus Wissenserhebung, Wissensrepräsentation, Wissensvalidierung angelehnt.

Die Phasen a) und b) sowie das Vorgehen zum Aufstellen der Netzwerkstruktur und das Bestimmen der Einflüsse werden anschaulich anhand des exemplarischen Beispielnetzwerke aus Abb. 35 und Abb. 38 erklärt. Die Erprobungsphase c) sowie unterschiedliche Leistungskriterien zum Bewerten von Ketten werden im Auswertekapitel (Kapitel 9) erläutert.

## 6.6.2 Prinzipien der Modellierung

Um eine gemeinsame Wissensrepräsentation aller Ketten zu erreichen, wäre eine umfassende Modellierung aller beteiligten Sensoren und Algorithmen sowie deren Einstellungen, kausaler und kontextueller Zusammenhänge und Randbedingungen hinweg erforderlich.

Diese monolithische Modellierung mit zentraler Wissensbasis ist jedoch aus den folgenden Gründen nicht ratsam:

- a) „Kein Experte weiß oder kann alles“: Das Expertenwissen über den Einsatz unterschiedlicher Sensoren oder Algorithmen ist meist nur punktuell und spezifisch.
- b) Die Komplexität und auch der Aufwand zum Erstellen und zur Überprüfung der Wissensbasis steigt mit der Zahl der betrachteten Ketten.
- c) Werden Änderungen an Ketten vorgenommen, neue Ketten integriert oder Ketten aus dem System entfernt, so müssten bei einer zentralen Wissensrepräsentation sämtliche Zusammenhänge erneut auf Korrektheit, Konsistenz sowie Widerspruchsfreiheit geprüft werden.
- d) Zusammenhänge und Annahmen über die Anpassungsfähigkeit bzw. Robustheit von Algorithmen in Bezug auf Umgebungsparameter sind häufig kettenspezifisch.

Dagegen könnte die im Konzept vorgeschlagene, kettenspezifische Modellierung zu einer Reduktion der Komplexität und damit zur besseren Nachvollziehbarkeit sowie Überprüfbarkeit führen, indem *dedizierte Wissensseinheiten für jede Kette separat modelliert* werden.

Zur Ableitung von Zusammenhängen, die bei der Erstellung von BNs benötigt werden, können folgenden Fragestellungen hilfreich sein:

- a) Welcher Einflussfaktoren und Randbedingungen (Kontext) sind zu berücksichtigen?
- b) Wie können quantitative Zusammenhänge erfasst oder „erlernt“ werden, um zu klären, wie „stark“ einzelne Faktoren die Leistung der Sensordatenverarbeitung beeinflussen?
- c) Lassen sich Ketten vergleichen?
- d) Können reale Sachverhalte präzise genug nachgebildet werden und sind die Ergebnisse der Modellierung reproduzierbar?

## 6.6.3 Kernelemente der Modellierung

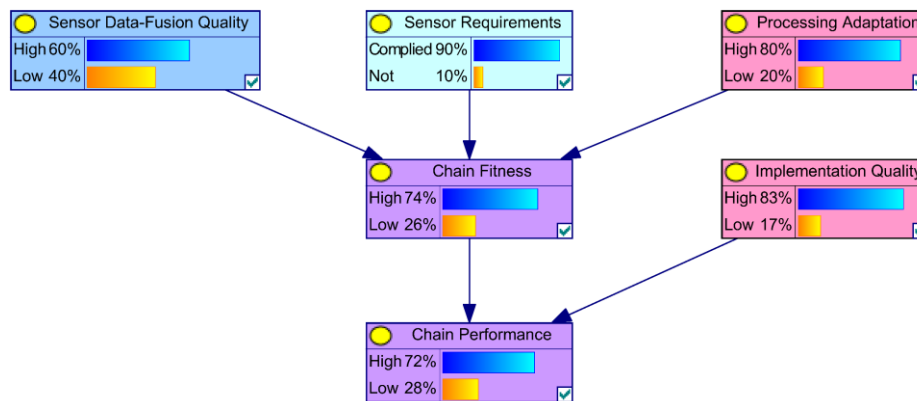
Mögliche und erwünschte Adaptionen der Bildverarbeitungsalgorithmen an Umgebungsparameter sollen explizit entwickelt, trainiert oder durch Experten vorgegeben werden. Dank dieser spezialisierter Parameter- und Datensets könnte eine höhere Kettenleistung (*Chain Performance*) erzielt werden, die jedoch nur für definierte Umgebungsparameter (*Processing Adaption*) erreicht wird. So können Algorithmen über Parameter- bzw. Trainingssets hinsichtlich Umgebungsparametern (Farbe und Struktur des Untergrundes, Temperatur, Lichtverhältnisse, Schattenwurf) optimiert werden.

Die Algorithmen der Ketten verarbeiten Sensordaten und stellen daher spezielle Anforderungen welche im BN als *Sensor Requirements* modelliert werden. Beispielsweise wären

Abhängigkeiten von der Perspektive, der GSD, dem Sensor-Footprint oder dem Overlap als Verbindungen im BN zu modellieren und in den entsprechenden CPTs zu quantifizieren.

Die Tauglichkeit von Ketten (*Chain Fitness*) ist sowohl von der Adaption der Algorithmen (*Processing Adaption*), vom Einhalten von Sensorvorgaben (*Sensor Requirements*) und gegebenenfalls von Qualität fusionierter Sensordaten (*Sensor Data-Fusion Quality*) abhängig.

Obige Kernelemente sind im BN in Abb. 33 mit ihren Abhängigkeiten dargestellt.



**Abb. 33:** Kernelemente der Modellierung der Kettenleistung via BNs: Die Zuverlässigkeit/Tauglichkeit („Chain Fitness“) von Ketten ist von der Adaption der Algorithmen, vom Einhalten von Sensorvorgaben („Sensor Requirements“) und zusätzlich von der erwarteten Sensordatenqualität („Sensor Data-Fusion Quality“) abhängig. Die resultierende Kettenleistung ergibt sich einerseits aus der modellierten Tauglichkeit und andererseits aus der Qualität der Implementierung (BV-Methode).

Die jeweiligen Einflüsse bzw. Abhängigkeiten sind hierbei kettenspezifisch und werden in Form von CPTs (Abb. 34) quantifiziert. Eine erste Abschätzung kann i.d.R. bereits während der Kettenentwicklung durch Entwickler abgeschätzt werden<sup>37</sup>. Danach werden die CPTs sukzessive anhand von repräsentativen Trainings-/Testdaten verifiziert und gegebenenfalls nachjustiert/verbessert. Diese ausgewählten Datensätze sollen idealerweise einen hohen Grad der möglichen Umweltvariationen abdecken, um so eine Generalisierung der Modellbildung zu ermöglichen.

Node properties: Chain Fitness

General Definition Format User properties

	Complied				Not			
	High		Low		High		Low	
Sensor Requirements	High	Low	High	Low	High	Low	High	Low
Processing Adaptation	0.7	0.6	0.2	0.5	0.2	0.05	0	0
Sensor Data-Fusion Quality	1	0.3	0.4	0.8	0.5	0.5	0.5	1
High	1	0.7	0.6	0.2	0.5	0.2	0.05	0
Low	0	0.3	0.4	0.8	0.5	0.5	0.5	1

<sup>37</sup> Das in Abb. 34 dargelegte Vorgehen zur übersichtlichen, intuitiven Eingabe von großen CPTs hat sich bewährt.

**Abb. 34:** CPT des *Chain Fitness* Knotens. Zur intuitiven, fehlerreduzierenden Vorgabe der Wahrscheinlichkeiten können die Eingangsknoten (*Sensor Requirements*, *Processing Adaption*, *Sensor Data-Fusion Quality*) gemäß ihrer erwarteten Einflussstärke sortiert werden. Ebenso sollten die jeweiligen Zustandsvariablen ausdrucksstark benannt und sortiert werden. Hierdurch kann meist eine übersichtliche Struktur erzielt werden, indem der „günstigste“ Fall oben-links (*Complied, High, High*) und der „ungünstige“ Fall rechts-unten (*Not Complied, Low, Low*) dargestellt wird. Die Einflüsse bzw. Wahrscheinlichkeiten für den günstigen Fall nehmen so meist von „links nach rechts“ ab. Dieses Vorgehen ist für große BNs und Knoten mit vielen Eingängen hilfreich, da die Größe der CPTs mit der Knotenanzahl rasch ansteigt und unübersichtlich werden kann.

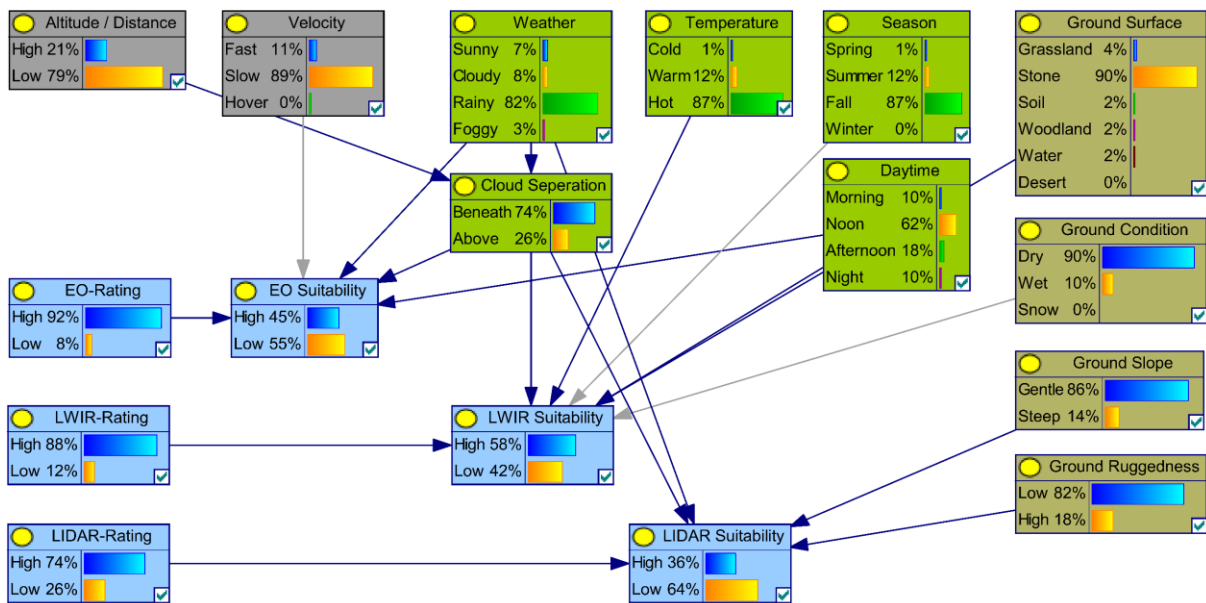
#### 6.6.4 Spezialisierung und Adaption von Ketten

Neben der Anpassungsfähigkeit an Umgebungsparameter (*Chain Fitness*) wird die absolute Leistungsfähigkeit der Ketten (*Chain Performance*) durch die gewählte Implementierung der Bildverarbeitungsalgorithmen bestimmt. Daher wird ein weiterer Knoten im BN eingeführt, der anhand der Trainings- bzw. Testdatensets zu bestimmen ist. Dieser Knoten (*Implementation Quality*) dient einerseits zur Normierung über sämtliche Ketten und andererseits zur Skalierung der Kettentauglichkeit bezüglich möglicher Leistungskennzahlen<sup>38</sup>.

Zum Modellieren der Umgebungs- und Umwelteinflüsse sind zunächst, die notwendigen Zustandsvariablen und deren Abhängigkeiten zu bestimmen, woraus sich direkt die Struktur des Bayesschen Netzes ableitet. Hierbei sollte die kausale Reihenfolge beibehalten werden, sodass die Ursache vor der Wirkung liegt, da sich so i.d.R. kompaktere und leichter modellierbare Netze ergeben (siehe Abb. 31). Das Vorgehen soll zunächst am vereinfachten BNs zur Modellierung der Tauglichkeit der Missionssensoren (*Suitability*) gemäß Abb. 35 erläutert werden. Die relevanten Zustands-, Umgebungs- und Umweltgrößen werden in die folgenden Kategorien unterteilt:

- *Plattform Zustände* (grau): Hierzu zählen u.a. die Entfernung zum oder Höhe über dem Beobachtungspunkt oder Geschwindigkeit des Fluggeräts.
- *Sensor-System Zustände* (blau): Neben einer allgemeinen Bewertung (*Rating*) des Sensorsystems (Sensorchip, Optik) werden zusätzliche Parameter wie Bodenauflösung (GSD), Bodenabdeckung, Abtastrate und die Sensorausrichtung berücksichtigt.
- *Wetter und Umweltzustände* (grün): In diese Kategorien fallen u.a. Witterung, Wolkenabstand, Temperatur sowie Jahres- und Tageszeit.
- *Topografische Eigenschaften* (braun): Neben der Art und Farbe des Untergrundes hat auch der Zustand des Untergrundes sowie die Neigung und die Oberflächenstruktur/-schroffheit direkten Einfluss auf die Tauglichkeit von Sensoren.

<sup>38</sup> Je nach Anwendung und Einsatz können verschiedene Leistungskennzahlen (Abschnitt 9.1: F0,5, F1, F2, AP) relevant sein. Unterschiedliche Leistungskennzahlen spielen besonders für den Einsatz von UAVs in militärischen Missionen eine wichtige Rolle [HHXB18].



**Abb. 35:** Vereinfachtes BN zur Abbildung der Tauglichkeit von Sensoren (*Suitability*) in Abhängigkeit des Plattformzustands (grau), von Wetter- und Umweltzuständen (grün), topografischen Gegebenheiten (braun) sowie einer Bewertung des Sensorsystems (*Rating*, blau).

Die Einflüsse fallen hierbei für jede Sensorart unterschiedlich stark aus. Im Rahmen dieser Arbeit wurden qualitative und quantitative Untersuchungen mit EO-, IR- und LIDAR-Sensoren anhand realer Flugversuche durchgeführt und ausgewertet. Für andere Sensorarten sind weitere Einflussfaktoren denkbar. So sind mit multi- oder hyperspektralen Sensoren Vegetations- und Materialarten (Textil, Plastik, Flüssigkeiten oder Gase) unterscheidbar. Folglich müssten hier zusätzliche vegetations- oder materialabhängige Aspekte im BN berücksichtigt werden

Entsprechend der kausalen Reihenfolge wird für jeden Elternknoten (Plattform, Umgebung, Umwelt: grau, grün, braun) geprüft, ob eine Beeinflussung der Kind-Tauglichkeitsknoten vorliegt. Diese Prüfung geschieht qualitativ aufgrund des Expertenwissens und empirisch durch Flugversuche und Auswertung. Bei starken und gut abschätzbaren Beeinflussungen wird eine Kante zwischen Eltern und Kindknoten eingeführt (z.B. Witterung → LIDAR-Tauglichkeit) und der CPT des Kindknotens um die Zustandsgrößen des Elternknotens erweitert und mit bedingten Wahrscheinlichkeiten gefüllt (Abb. 35).

Node properties: LIDAR Suitability

Weather	Sunny	Cloudy	Rainy												Foggy
LIDAR-Rating	...	...	High						Low						...
Cloud Separation	...	...	Beneath			Above			Beneath			Above			...
Ground Ruggedness	...	...	Low	High	Low	High	Low	High	Low	High	Low	High	Low	High	...
Ground Slope	...	...	Gentle	Steep	Gentle	Steep	Gentle	Steep	Gentle	Steep	Gentle	Steep	Gentle	Steep	...
High	...	...	0.5	0.4	0.2	0.1	0.3	0.2	0.1	0.05	0	0	0	0	...
Low	...	...	0.5	0.6	0.8	0.9	0.7	0.8	0.9	0.95	1	1	1	1	...

**Abb. 36:** CPT-Ausschnitt zur Abschätzung der verminderten Tauglichkeit des eingesetzten LIDAR Sensors unter erschwerten Witterungs- und Umgebungsbedingungen. Bei Vorhandensein von Fremdpartikeln kommt es zu Streuungen und Reflexionen, so dass statt einer Vermessung des Untergrundes die Entfernung zu den Partikeln gemessen wird. Der Effekt nimmt mit Partikelgröße und -dichte (Gase, Tröpfchen, Wolken, Staub) zu.

Für schwache Abhängigkeiten muss entschieden werden, ob neue Verknüpfungen eingefügt werden, d.h. ob eine geringfügig erhöhte Aussagestärke der Modellierung eine zusätzliche Komplexität und Fehleranfälligkeit des Netzes rechtfertigt. Da mit steigender Komplexität des

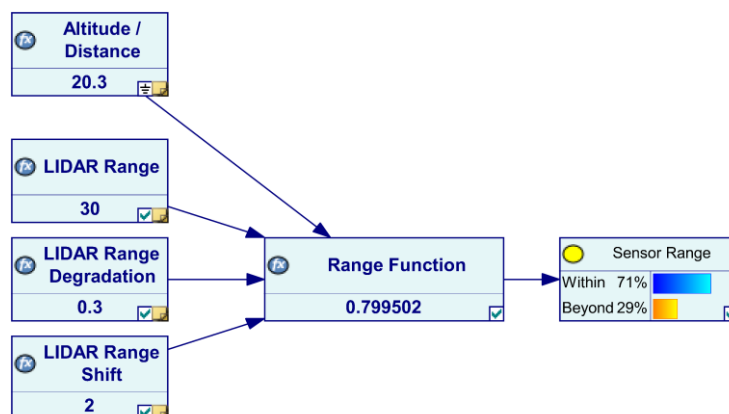
BNs häufig Transparenz, Akzeptanz und Wartbarkeit der Modellierung sinken [Bmwi21], sollten die Zustandsgrößen pro Knoten möglichst klein gehalten werden. Neben der Fokussierung auf markante Einflussfaktoren können zusätzliche Zwischenknoten eingeführt werden, da so die Knotenanzahl des BNs zwar insgesamt steigt, die Anzahl Verbindungen pro Knoten und damit die Größe der CPTs jedoch überschaubar bleibt. Gleichzeitig sind diese Zwischenknoten (u.a. *Motion Blur*, *Shadowing*, *Sensor Range* in Abb. 38) häufig intuitiv modellierbar und können gut zur Diagnose und zur Ableitung von Plattformwünschen herangezogen werden.

### 6.6.5 Diskretisierung und hybride Bayessche Netze

Die bisherigen, klassischen BNs bestehen aus diskreten Knoten (z.B. *Suitability*) mit einer endlichen Menge sich gegenseitig ausschließender Zustände (z.B. *High-Low*, *Gentle-Steep*) und Wahrscheinlichkeitswerten im Bereich  $[0, 1] \in R$ . Einige Plattform- und Sensorparameter sowie Zusammenhänge wie die Reichweiten-beschränkung (*Sensor Range*) oder die Einhaltung einer geforderten Bodenauflösung oder -abdeckung (*Footprint*) beruhen auf kontinuierlichen Wertebereichen.

Um Größen wie Sensorauflösung, Winkel und Entfernungen mit hoher Präzision abbilden zu können, werden funktionale Blöcke, sogenannte „*Equation nodes*“, verwendet. Diese Knoten können neben diskreten auch kontinuierliche Elternknoten besitzen und bieten die Möglichkeit mehrdimensionale Funktionen abzubilden. Anschließend müssen ihre Zustände erneut auf den Bereich  $[0,0 ; 1,0]$  skaliert und diskretisiert werden, damit die berechneten Zusammenhänge von (diskreten) Kindknoten genutzt werden können. Solche Netze werden als *hybride Bayessche Netze* bezeichnet.

Hybride BNs können entweder direkt als Teil des BNs eingeführt oder zur Steigerung der Übersichtlichkeit als Subnetz eines Knotens eingeführt werden. So kann je nach Modellierungsgrad die modellierte Sensorreichweite des LIDAR Sensors (Abb. 37) entweder als *LIDAR-Rating* Subnetz (Abb. 35) oder als zusätzlicher Zwischenknoten (*Sensor Range* im erweiterten BN gemäß Abb. 38) eingeführt werden. In beiden Fällen wird der Ausgang im verbundenen Kindknoten (*LIDAR Suitability*) genutzt, um zu einer Abschätzung der Qualität der LIDAR Daten zu gelangen.



**Abb. 37:** Hybrides BN am Beispiel der Modellierung der Sensorreichweite des LIDAR Sensors: Durch funktionale Blöcke („*Equation nodes*“) können kontinuierliche Werte im BN verrechnet werden. Nach anschließender Skalierung und Diskretisierung können die Ergebnisse Kindknoten (Abb. 38, *LIDAR Suitability*) genutzt werden.

### 6.6.6 Einflussfaktoren und Modellierungsvorlage

*Wahrnehmungsaufgaben* wie das Erkennen von Personen oder Fahrzeugen bestehen häufig aus einem mehrstufigen Wahrnehmungsprozess (siehe „*Perception-Module-Graph*“ in Abb. 27). Um die unterschiedlichen Merkmalsräume bzw. -klassen trennen zu können und um die Rechenzeit zu optimieren, müssen bestimmte *Annahmen (Hypothesen)* getroffen werden<sup>39</sup>. Diese Annahmen sind allerdings häufig nur für *bestimmte Umwelt- und Sensorzustände oder -konstellationen* gültig, die zudem durch Störgrößen wie Schattenbildung, Reflexionen oder Bewegungsunschärfe nachteilig beeinflusst werden.

Zur Abbildung ganzer Ketten müssen daher die Kernelemente (Abb. 33) sowie die Modellierung der Sensorqualität nach Abb. 35 um weitere Knoten ergänzt werden. Einer Vorlage zur Modellierung (Abb. 38) sind sämtliche Knoten eingefügt, wobei für konkrete Ketten, nur die Knoten zu verbinden und diejenigen CPTs zu befüllen sind, welche relevante Einflüsse und Zusammenhänge repräsentieren. Ungenutzte Knoten und Verbindungen, z.B. aufgrund nicht eingesetzter Sensoren, können anschließend entweder gelöscht oder deaktiviert werden, indem die CPTs mit gleichverteilten Wahrscheinlichkeiten gefüllt werden.

Mögliche Erweiterungen können dabei die folgenden Aspekte umfassen:

- *Sensor-Zwischenknoten* (blau): Diese Knoten stellen den direkten Einfluss auf die Tauglichkeit der Missionssensoren dar. Sie dienen einerseits zur verständlichen Modellierung, reduzieren die Größe der CPTs und können für Diagnosezwecke genutzt werden. Mögliche Zwischenknoten sind die Bewegungsunschärfe, der Schattenwurf, Reflexionen, der Kontrastumfang sowie die Sensorreichweite.
- *Sensorsystem-Konfigurationen* (türkis): Diese Eingangsknoten stellen Einstellungsmöglichkeiten und Parameter des Sensorsystems dar. Sie sind entweder fest durch das Sensorsystem (Chip, Optik, Gimbal)<sup>40</sup> vorgegeben oder manuell (Payload-Operator) bzw. automatisch (Sensormanagement siehe Konzept in Abschnitt 5.1) an den jeweiligen missions- oder situativen Kontext anpassbar.
- *Szenen- bzw. Situationsbeschreibung* (gelb): Über diese Eingangsknoten kann Vorwissen über den Einsatzzweck und die Szenerie näher spezifiziert werden. Hierzu zählen u.a. die Entfernung zum Ziel, mögliche Verdeckungen, die Einsatzraum, die Objektgröße, die Objektgeschwindigkeit oder die Objektfarbe bzw. Tarnung. Diese Größen dienen zur Abschätzung der Anpassungsfähigkeit der Algorithmen (*Processing Adaption*) oder zur Berechnung und Einhaltung von *Sensor-Requirements*.
- *Datenverfügbarkeit* (orange): Hier kann die Abhängigkeit und Verfügbarkeit von relevanten Daten, beispielsweise GIS-Daten und Referenzsensordaten, angegeben werden.

---

<sup>39</sup> Diese Modelle der eingesetzten Bildverarbeitungsmethoden werden Auswertungskapitel 9 ausführlich erläutert. Spezialisierungen über die Netzarchitektur und insbesondere durch optimierte, d.h. an Umgebungs- und Sensorparameter angepasste Datensets, führen dabei zu einer kettenspezifischen Modellierung.

<sup>40</sup> So können bei Zoomobjektiven die Bodenauflösung und -abdeckung variiert werden, über Blende und Belichtungszeit die Bildwiederholrate eingestellt werden oder mit Hilfe von Gimbals die Perspektive vorgegeben werden.



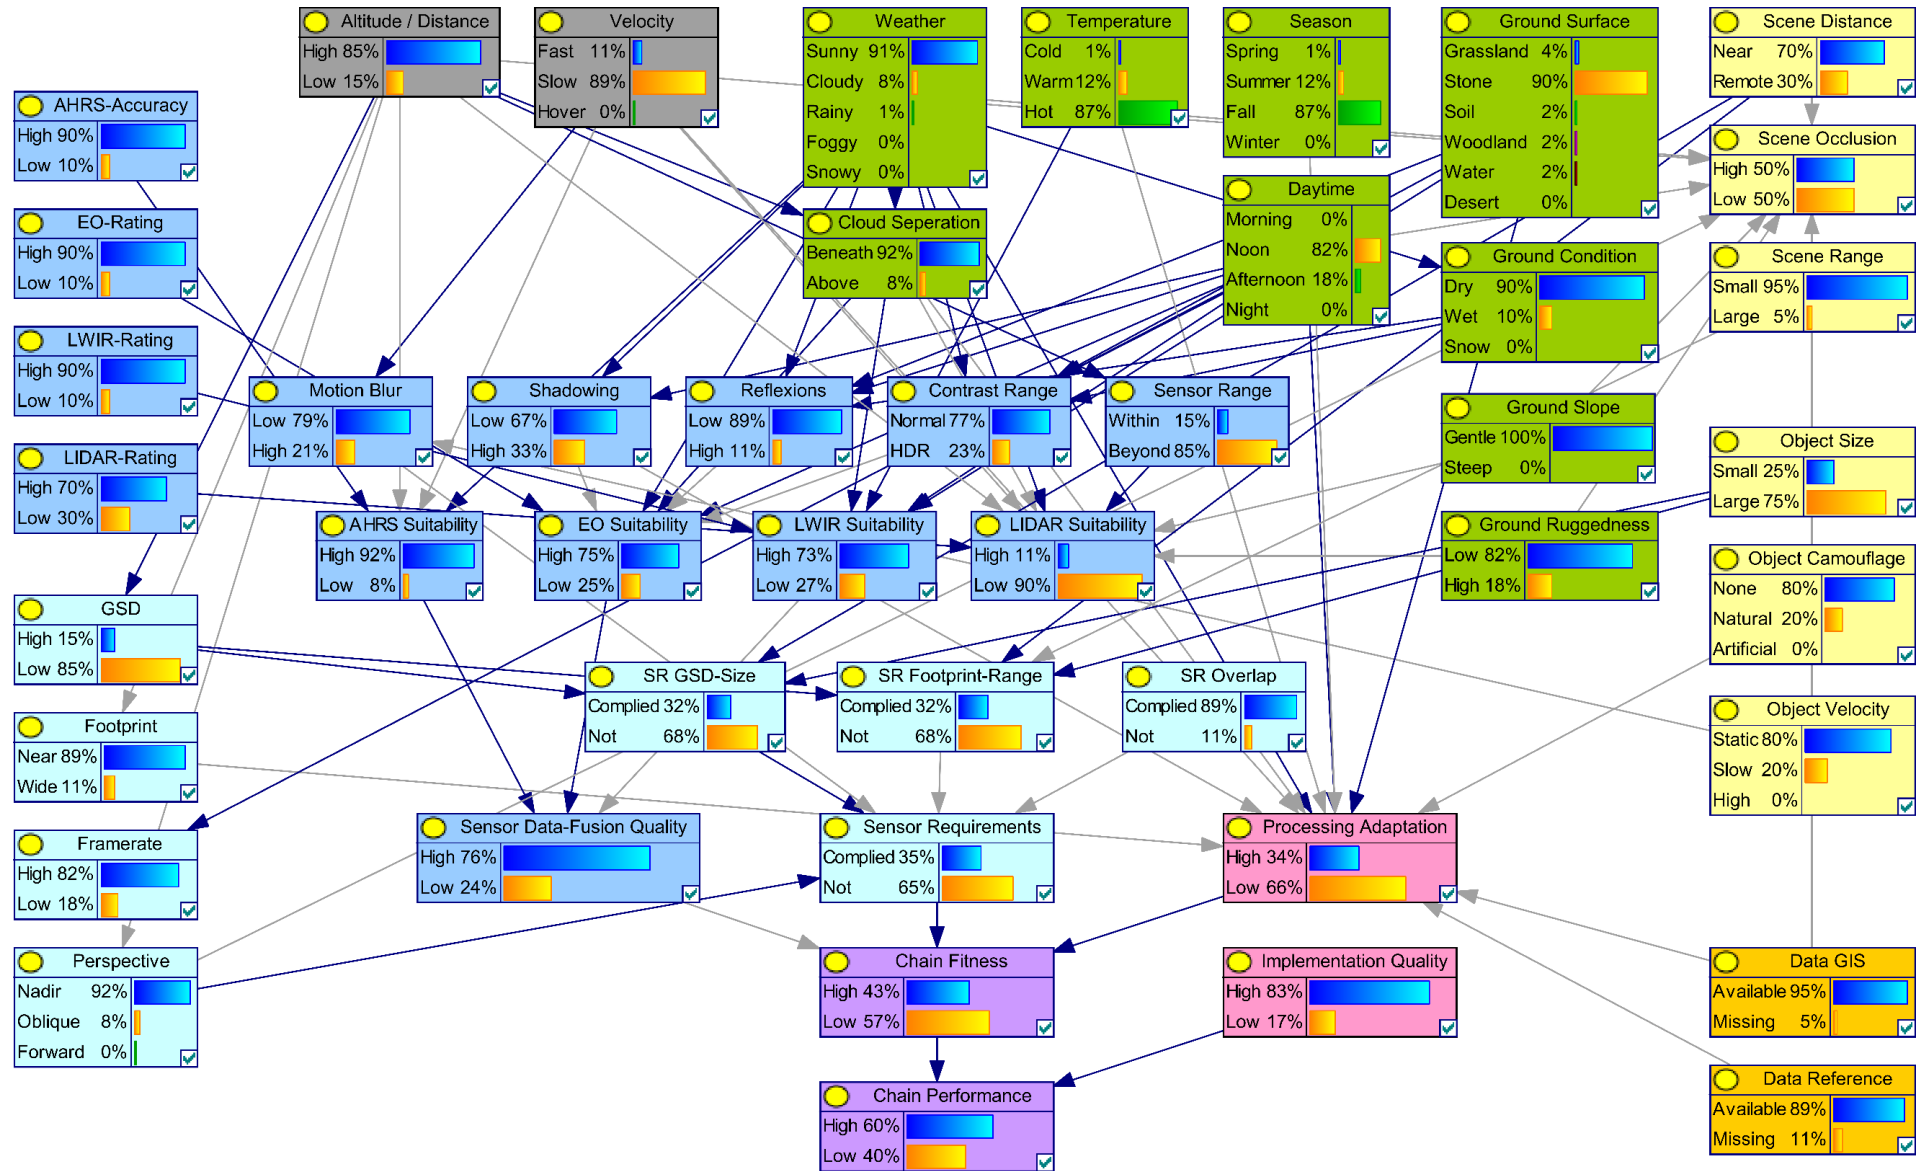


Abb. 38: Modellierung der Sensor- und Wahrnehmungsfähigkeiten als BN.



## 7. Auswahl von Ketten

Um die Gesamtleistung zu verbessern, basiert das SPMS auf der Annahme, alternative Ketten gezielt einzusetzen. Diese Ketten sind für spezifische Aufgaben wie die Fahrzeug- oder Personenerkennung zuständig. Sie werden darauf optimiert, bestimmte Umgebungsparameter oder einen geringen Ressourcenverbrauch zu berücksichtigen. Dies wird erreicht, indem redundante Sensorsysteme bzw. Sensoreinstellungen sowie verschiedene Methoden und Algorithmen verwendet werden, zum Beispiel durch das Training mit spezialisierten Parametersets.

Um die alternativen Ketten zu einem Gesamtsystem zu vereinen und eine optimierte Auswahl während des Fluges zu ermöglichen, sind ein verteiltes Kettenmanagement (Abschnitt 7.1) und eine multikriterielle Kettenbewertung (Abschnitt 7.2) erforderlich. Gemäß dem SPMS-Konzept erfolgt dies durch das Zusammenspiel zwischen dem *Perception Solver*, dem *Processing Coordinator*, den *Ketten* und dem *Conditions-Monitor*. Das verteilte Kettenmanagement übernimmt dabei die Koordination und Steuerung der einzelnen Ketten, während die multikriterielle Kettenbewertung die Ketten anhand verschiedener Kriterien bewertet und ihre Rangfolge festlegt. Die zur Bewertung notwendige Kettenleistung soll durch Auswertung der in Abschnitt 6.6 beschriebenen Kettenmodellbildung abgeschätzt werden.

Die Anforderungen (Abschnitt 4.1) wurden berücksichtigt, damit das System robust ist, sich flexibel anpassen lässt, eine klare Nachvollziehbarkeit gewährleistet und so dem Payload-Operateur die Möglichkeit bietet, aktiv in das System einzugreifen.

Abschließend werden in diesem Kapitel die grundlegenden Funktionalitäten der implementierten Realisierung untersucht (Abschnitt 7.3).

### 7.1 Kettenmanagement

Gemäß Abb. 26 soll das Kettenmanagement durch das Zusammenspiel zwischen dem *Perception-Solver* (PS), *Processing-Coordinator* (PC), den *Ketten* und dem *Ressourcen-Monitor* (RM) realisiert werden.

#### 7.1.1 Koordination von Ketten

Um die Erweiterbarkeit und den möglichen Ausfall von Ketten berücksichtigen zu können, müssen sich Ketten dynamisch und spontan mit dem PC verbinden und trennen können.

Zum Nachrichtenaustausch (MMS, PS, PC, RM, Ketten) eignet sich daher ein verteiltes, entkoppeltes Schema nach dem *publisher-subscriber-Prinzip* [TaSt17]. Hierbei kommen zwei verschiedene Teilnehmerarten vor: der Nachrichten-Broker und die Clients. Die Aufgabe des *Brokers* ist die transparente Nachrichtenverwaltung und -verteilung zwischen den Clients. Entsprechend des Nachrichtinhalts kommen als *Client* beispielsweise der PC oder die Ketten in Frage, wobei diese nie direkt miteinander kommunizieren, sondern Nachrichten „*publishen*“ (veröffentlichen) und „*subscriben*“ (abonnieren).

Wie im Konzeptkapitel anhand des Perception-Module-Graph (Abb. 27) erläutert wurde, soll zur Bearbeitung von Wahrnehmungsaufträgen (MMS) der Lösungsraum aller alternativen Ketten vom PS durchsucht werden. In Anlehnung an [Bich00, BiKa05, PTWW15, ShMS15]<sup>41</sup> wird als Architektur eine *Multi-Attribute Reverse Auction* zur Kettenauswahl implementiert. Um diesen „*Wahrnehmungs-Fähigkeiten-Markt der Ketten*“ realisieren zu können, werden zusätzliche Definitionen und Schnittstellen zwischen Wahrnehmungsaufträgen (MMS), Ketten und Wegpunkten benötigt:

- Die *Kettenbeschreibungen* dienen der Angebotserstellung (*Perception-Bid*), der Koordination und der Überwachung des Marktes. Sie beinhalten Angaben über die implementierte Wahrnehmungsaufgabe (*Perception-Tasks*), eine eindeutige Ketten-ID und Prozess-ID sowie der voraussichtliche Ressourcenbedarf und die abgeschätzte Kettenleistung (Abschnitt 6.6).
- *Auktionen* werden vom PC gestellt. Nach dem Veröffentlichen wartet der PC innerhalb der Auktionsfrist auf gültige Angebote der Ketten. Zum Prüfen, Bewerten und Zuordnen der Angebote werden für Auktionen die folgenden Informationen benötigt: welche Wahrnehmungsaufgabe wird in der Auktion angefragt<sup>42</sup>, eindeutige Auktions-ID, eine Auktionsrunden-ID zur Aktualisierung von Auktionen und die Vorgabe von Prioritäten sowie wahlweise einen bevorzugten Sensortyp und Angaben über den Einsatzort.

Eine oder mehrere Auktionen sind entweder direkt mit Wegpunkten verknüpft oder können vom MMS bzw. dem Operateur manuell konfiguriert und gestartet werden. Gemäß dem SPMS-Konzept sind das Wegpunktmanagement und die Erstellung von Auftragslisten Teilfunktionalitäten des MMS (Abb. 47).

Die Funktionen und der schematische Ablauf des Kettenmanagements sind als Prozessdiagramm in Abb. 39 dargestellt. Der marktbasierter Ansatz (*Perception-Market, PM*) umfasst neben dem Nachrichtenaustausch die folgenden Hauptaufgaben:

- *Capability Collection (grün)*: Abfrage sämtlicher Kettenfähigkeiten, um so die Gesamtfähigkeit über das SPMS (Einsatzraum) aggregieren zu können
- *Winner-Determination (blau)*: (Vor-)/Auswahl und Bewertung von Ketten
- *Runtime-Control (orange)*: Aktivierung und Priorisierung geeigneter Ketten sowie Zuteilung von Ressourcen
- *Monitoring (lila)*: Überwachung von Änderungen der Umgebungsparameter und Ressourcen sowie gegebenenfalls Reinitialisierung des Bewertungsprozesses

Die Ermittlung sämtlicher Wahrnehmungsaufgaben (*Capability Collection, grün*) und die Bestimmung und Bewertung geeigneter Ketten (*Winner-Determination, blau*) verläuft hierbei

<sup>41</sup> Multi-Attribute Reverse Auction: Reverse bezieht sich hierbei darauf, dass es nur einen Käufer (PC) aber mehrere Anbieter bzw. Verkäufer (Ketten) gibt. Bei Multi-Attribute Auktionen beinhaltet ein Angebot (Bid) mehrere Kriterien (Kettenleistung, Ressourcenverbrauch), die für den Zuschlag berücksichtigt werden.

<sup>42</sup> Als Wahrnehmungsaufgabentypen stehen neben der Übertragung von Sensorbildern die Detektion, Identifikation sowie das Verfolgen von Objekten (Fahrzeugen, Personen, Hindernissen) zur Auswahl.

analog. Obige Schnittstellen und Definitionen und der verteilte Nachrichtenaustausch zwischen PM und Ketten werden wie folgt genutzt:

- Sämtliche Ketten abonnieren Auktionen und werden vom Broker benachrichtigt, falls entweder eine konkrete Wahrnehmungsaufgabe oder alle Wahrnehmungsfähigkeiten (*Request Capabilities*) vom PC angefragt werden.
- Die Auktionen werden mit einer Ablaufrist versehen und für jede Auktion wird die Task-ID wahlweise inkrementiert oder mit einem eindeutigen Hash-Wert versehen<sup>43</sup>.
- Durch die Vorgabe von zusätzlichen Bedingungen (*Capability-Constraints*) kann während der Auktion bereits eine Vorauswahl der Ketten getroffen werden [SaSh16]. So lassen sich die alternativen Ketten hinsichtlich ihres Aufgabentyps, der Sensorart oder des Einsatzortes vorab filtern<sup>44</sup>.
- Ein Fähigkeitstypenabgleich wird für jede Kette intern durchgeführt. Die anschließende Auswertung der Leistungsmodelle sowie das Erstellen und Übermitteln der Angebote (*Bids*) wird nur durchgeführt, falls der Abgleich erfolgreich war (grüne Pfeile, Abb. 39).
- Der PC abonniert *Perception-Bids* und wird kontinuierlich über die gültigen und aktuell verfügbaren Wahrnehmungsfähigkeiten des Marktes benachrichtigt.

Im Gegensatz zu einer zentralen Filterung durch den PC bietet die ketteninterne Fähigkeitsbestimmung einige Laufzeitvorteile:

- Das Nachrichtenaufkommen und die benötigte Bandbreite werden verringert.
- Der Verzicht auf die Auswertung nicht benötigter Leistungsmodelle (*roter Pfeil*) führt zu einem geringeren Ressourcenverbrauch (Rechenzeit).
- Durch eine geringere Anzahl zu überwachender Kettennachrichten (PC) sinkt die Systemkomplexität und damit die Fehleranfälligkeit.

### 7.1.2 Rangfolgeerstellung von Ketten

Nach Ablauf der Auktionsfrist werden die Angebote der Ketten vom PC ausgewertet (*Winner-Chain-Determination, WCD, blau*). Jedes Angebot beinhaltet den erwarteten Nutzen (Leistungskriterien  $P_i$ ) sowie den voraussichtlichen Ressourcenverbrauch ( $R_i$ ). Die Erstellung einer Kettenrangfolge im Zuge des Vergleichs und der Bewertung der Angebote kann daher als multikriterielles Entscheidungsproblem (Abschnitt 7.2) aufgefasst werden.

Je nach Mission oder Situation können vom Payload-Operateur oder dem MMS unterschiedliche Gewichtungen der einzelnen Kriterien erstrebenswert sein. Hieraus ergeben sich neue, situationsoptimale Bewertungen der Ketten, die sich in einer aktualisierten Rangfolge und Priorisierung der Ketten widerspiegeln. Die Details zum eingesetzten

---

<sup>43</sup> Über die Ablaufrist wird einerseits der Ausfall sowie das Blockieren von Ketten abgefangen und zusätzlich ein sich wiederholendes Umschalten zwischen ähnlichen Ketten verhindert. Als Hash-Wert wird in der Implementierung ein *Universally Unique Identifier* (UUID) verwendet.

<sup>44</sup> Um sämtliche Fähigkeiten anhand der Umgebungsparameter einzusammeln, wird folglich auf die Vor-Filterung verzichtet, indem als Typ = RequestCapabilities, Sensor = Any, Location = Any gesetzt werden. Eine Vorfilterung aufgrund einer mindestens geforderten Leistung oder eines maximalen Ressourcenverbrauches ist dabei nicht ratsam, da gegebenenfalls auch eine geringe Leistung immer noch erstrebenswerter sein kann, als der Fall, dass keine Kette, die Anforderungen erfüllt.

Bewertungsprozess werden im nachfolgenden Unterkapitel (Abschnitt 7.2) hergeleitet und im Auswertekapitel (Kapitel 9) anhand unterschiedlicher Bewertungsfunktionen weiter diskutiert.

Aus der Rangfolge und der Aufgabenpriorität werden die Laufzeitparameter (Aktivität, Prozess-PID, Prozess-Priorität) von Ketten erstellt oder angepasst. Zum gezielten Stoppen, Starten und Priorisieren von Ketten werden neben Laufzeitparametern auch die Task-IDs, Ketten-IDs sowie die aktuell verfügbaren Ressourcen vom PC in einer Datenbank gespeichert (*Bookkeeping*). Bei der (De-)/Aktivierung von Wahrnehmungsaufgaben über den *Perceptions-Solver* sowie beim Aktualisieren von Auktionen wird diese Datenbank zum Scheduling der Ketten ausgewertet, indem z.B. für jede Task-ID die ausgeführten Prozesse (Chain-PIDs) gestoppt oder neu priorisiert werden.

### 7.1.3 Monitoring und Neubewertung

Während der Mission können sich sowohl die Umgebungsparameter als auch die verfügbaren Ressourcen so stark ändern, dass die vorhergesagte Kettenleistung und damit die erstellte Rangfolge der Ketten den aktuellen Zustand nicht mehr ausreichend repräsentieren.

Daher soll das System in der Lage sein, relevante Eingangsparameter zu überwachen und deren Änderungen bzw. Änderungsraten (vgl. Abb. 38) zu erkennen (*Monitoring, violett*)<sup>45</sup>. Falls diese Alarm-Schranken überschritten werden, so wird automatisch eine Neubewertung der Ketten durchgeführt:

- Die Wahrnehmungsauktionen werden mit den bisherigen Auktions-IDs bzw. Task-IDs wiederholt und die Auktionsrunden-IDs werden inkrementiert.
- Die aktualisierten Auktionen werden von den Ketten registriert, woraufhin die Leistungsmodelle mit den aktuellen Umgebungsparameter neu ausgewertet werden.
- Hieraus resultieren neue Angebote, die vom PC erneut bewertet und sortiert werden.

Durch mögliche Änderungen der Winner-Chain Reihenfolge, kann so ein Umschalten auf neue und besser adaptierte Ketten nötig werden.

Ein Umschaltvorgang kann das Suchen, Beenden, Starten oder Priorisieren von Prozessen, das Laden neuer Parametersets und evtl. auch den Wechsel auf andere Sensoren beeinhaltet. Jeder Umschaltvorgang ist damit mit Latenzen behaftet. Dies kann zu einem Aussetzen bzw. Pausieren der Verarbeitung und damit zu einem Verlust oder zu einem verzögerten Erkennen von Perzepten führen, was u.a. die Objektverfolgung (Tracking) erschwert. Für dynamische Situationen oder Missionen ist folglich die Anzahl der Umschaltvorgänge möglichst zu reduzieren. Eine Neubewertung ist daher nur dann vorgesehen, wenn:

---

<sup>45</sup> Die Umgebungs-, Sensor- und Plattformzustände sowie die Ressourcen werden hierfür vom *Conditions-Monitor* berechnet und im Markt verteilt (*publish*). Die Alarm-Schranken werden zentral vom PC überwacht, wobei zusätzlich die jeweils aktiven Ketten (*Winner-Chains*) ihre ursprünglich prädizierte Leistung (Stand letzte Auktion) mit der aktuell geschätzten Leistung vergleichen. Hierdurch können einerseits global Änderungen über alle und somit auch für nicht aktive Ketten sowie konkrete Leistungsänderungen der aktiven Ketten zur Alarmierung berücksichtigt werden.

- *Neue oder veränderte Aufgaben* eintreten. Dies geschieht, indem ein neuer Wegpunkt erreicht wird oder Änderungen vom MMS bzw. Payload Operator angefragt werden.
- Die *Umweltzustände oder verfügbaren Ressourcen* sich ändern. Diese Änderungen werden kontinuierlich vom PC überwacht und können globale Änderungen an der Rangfolge über alle Ketten zur Folge haben.
- Die *Kettenzuverlässigkeit* sich wesentlich *verschlechtert*. Hierzu überwachen die jeweils aktiven Ketten ihre Leistungsmodelle selbstständig und melden das Unter-/Überschreiten von prozentualen oder relativen Schwellwerten.
- *Periodisch* wiederkehrende *Monitoraufgaben* aktiviert sind. Diese Überprüfung aller aufgabenrelevanter Ketten soll einen zusätzlichen Abgleich zwischen den Ketten schaffen, da mehrere kleine Änderungen eine Änderung der Kettenrangfolge nach sich ziehen können.

Die Ergebnisse der aktiven Ketten werden in Form von Perzepten dem *Result-Validator* (Abschnitt 5.4) zur Verfügung gestellt. Um die Ergebnisse unterschiedlicher Ketten nutzen, vergleichen, validieren oder fusionieren zu können, werden von allen Ketten die Ergebnisse in einem einheitlichen Format veröffentlicht und vom RV abonniert. Neben dem Objekt-Typ umfasst dies u.a. eine örtliche Objektbeschreibung (Segmentierung), den Sensor-Typ, die Art des Untergrundes sowie die Zuverlässigkeit im Wertebereich zwischen 0 und 1.

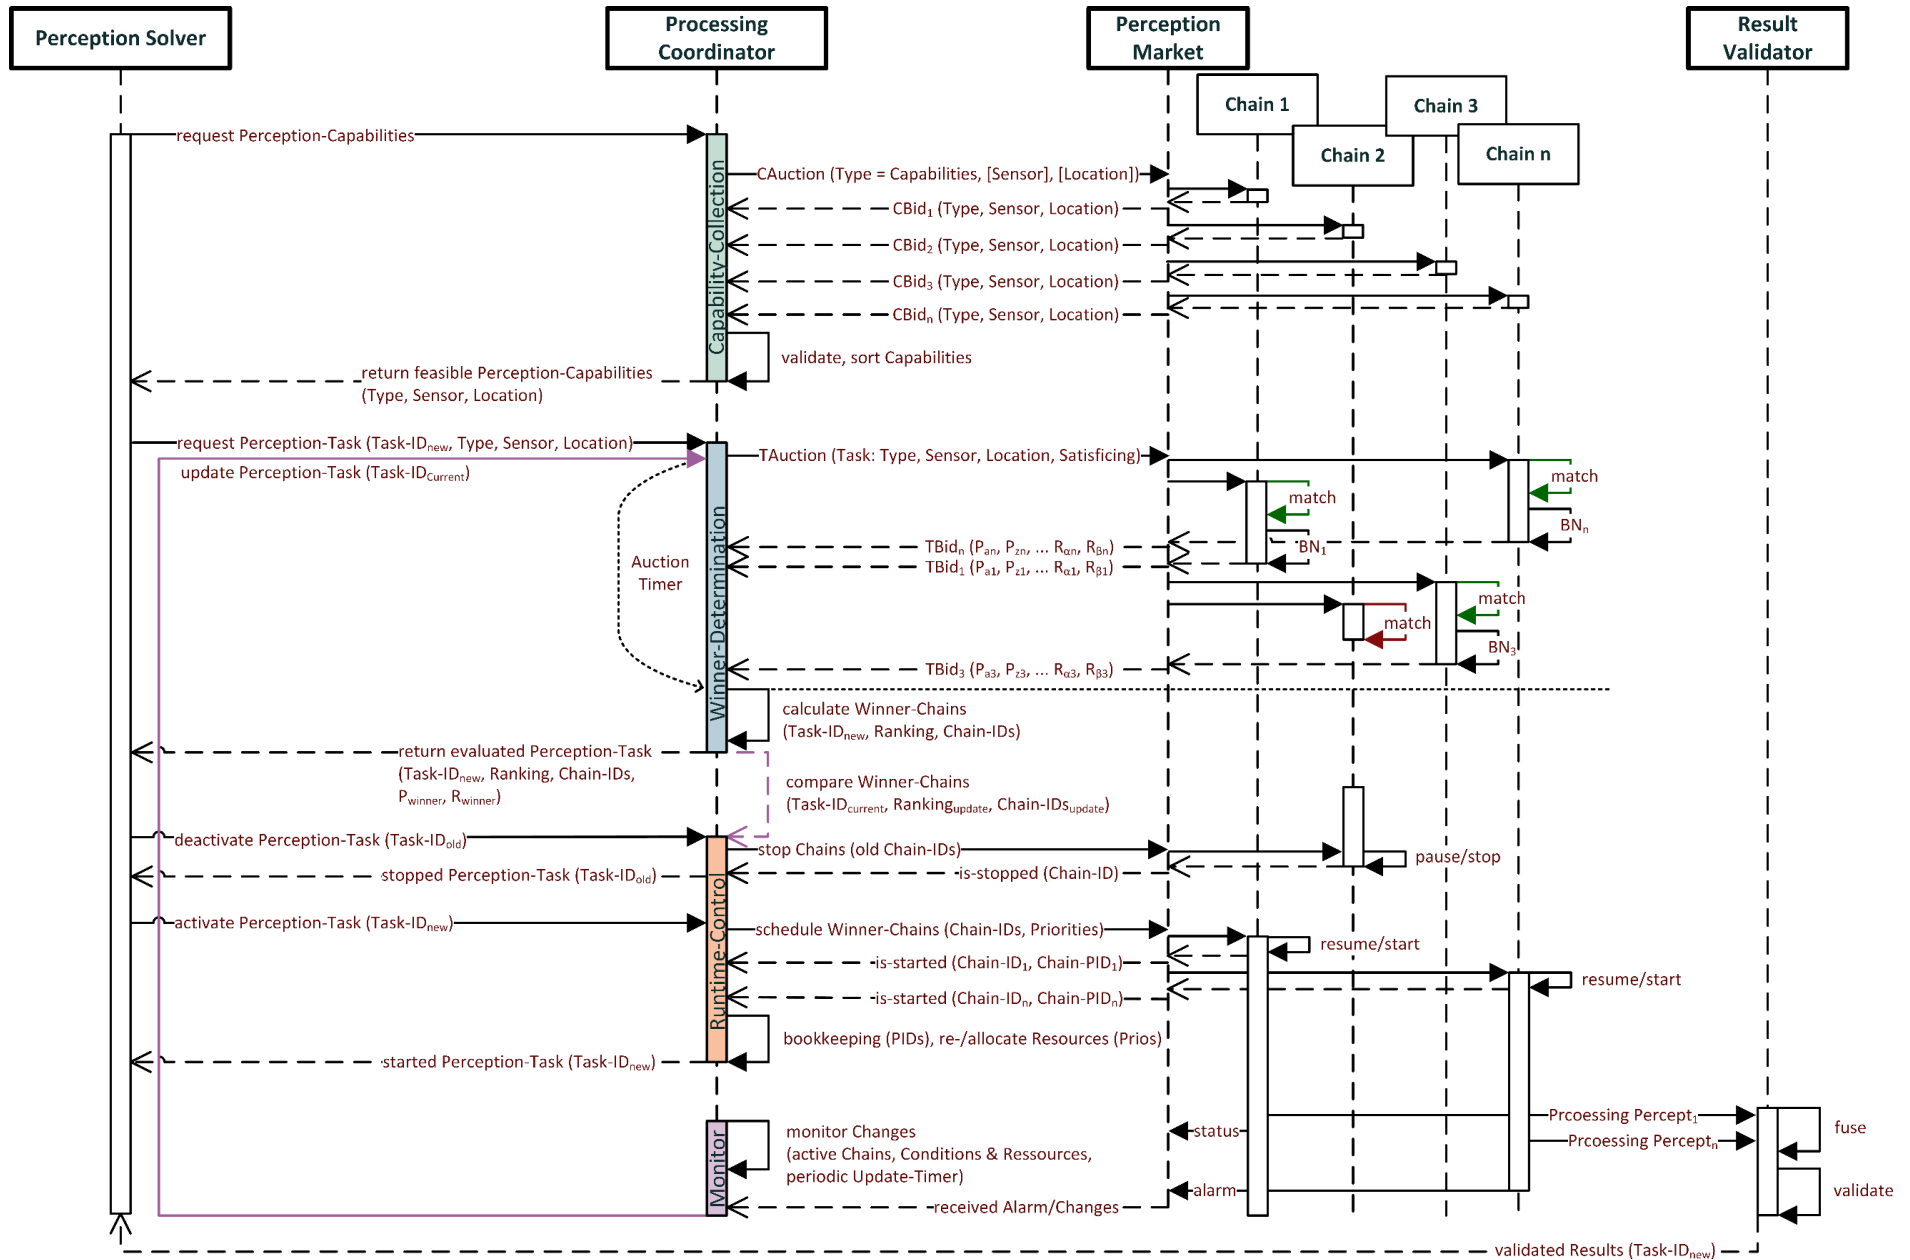


Abb. 39: Prozessdiagramm zur Veranschaulichung der Ablaufsteuerung des Kettenmanagements.

## 7.2 Multikriterielle Kettenbewertung

Für die optimierte Auswahl von Ketten können gleichzeitig mehrere Kriterien von Relevanz sein. Im Rahmen dieser Arbeit werden die Kettenleistung und der Ressourcenverbrauch berücksichtigt. Andere missions- oder situationsrelevante Kriterien wären die verbleibende UAV-Reichweite, das Gefährdungspotential, die Sichtbarkeit oder die Datenlink-Verfügbarkeit. Die einzelnen Kriterien können sich hierbei ergänzen oder sich gegenseitig negativ beeinflussen oder ausschließen.

### 7.2.1 Optimierungsaufgabe

Um einzelne Ketten anhand von Laufzeitparametern gezielt starten, stoppen oder mit Prioritäten versehen zu können, wird eine situationsoptimale Kettenrangfolge benötigt. Zum Ableiten dieser Rangfolge wird eine multikriterielle *Bewertungsfunktion*  $w$  nach Abb. 40 gesucht.

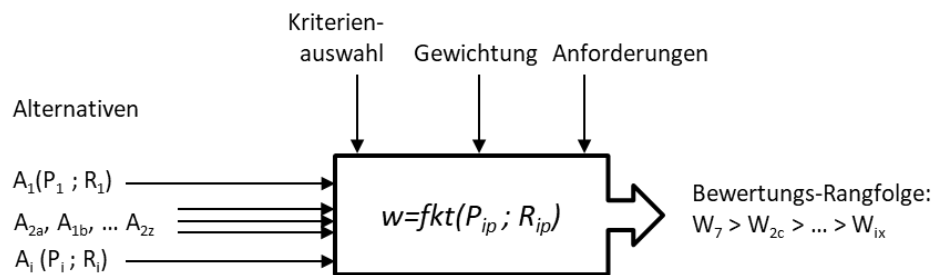


Abb. 40: Bewertungsschema zur Rangfolgeerstellung alternativer Ketten.

Als *Entscheidungs-Alternativen* werden die Ketten und spezialisierte Parametrisierungen der Ketten (*Ketten-Permutationen*) betrachtet. Diese Alternativen werden vorab auf definierte Umweltzustände hin adaptiert, optimiert und getestet, um so die zur Vorhersage der Kettenleistung  $P_i$  notwendigen Kettenmodelle erstellen und auswerten zu können. Im Zuge der Konzeptevaluierung wird neben der Kettenleistung und nur der Ressourcenverbrauch berücksichtigt. Folglich sind die Erkennungsleistung  $P_i$  der Ketten sowie deren voraussichtlicher Verbrauch unterschiedlicher Ressourcen  $R_i$  als relevante Kriterien in der Kettenbewertung zu optimieren.

Um den Auswahlprozess an die aktuellen Einsatzanforderungen (z. B. hohe Zuverlässigkeit bei der Vermisstensuche) und die verfügbaren oder geplanten Ressourcen anzupassen, sind die Vorgabe von Gewichtungparametern und Anspruchsniveaus vorgesehen. Dadurch kann das MMS bzw. der Payload-Operator eine Auswahl treffen, die speziell auf die Mission und die aktuelle Situation zugeschnitten ist (vgl. Abb. 40).

### 7.2.2 Herleitung der eingesetzten Bewertungsfunktion

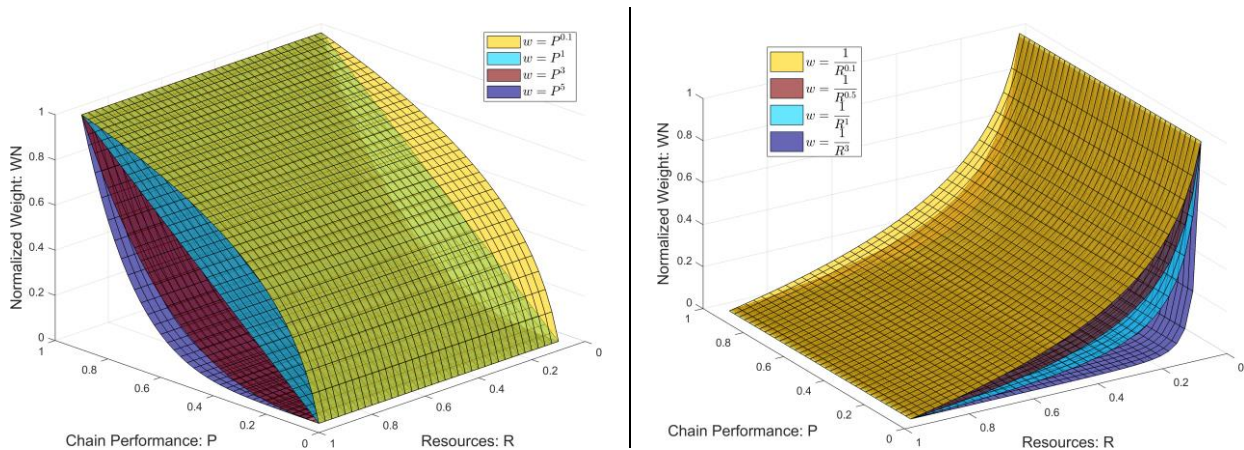
Die zur Optimierungsaufgabe (Abschnitt 7.2.1) eingesetzte *Bewertungsfunktion*  $w$  kann nach [Geld14, LaGS14, Zimm08] den Einzelsynthese-Verfahren<sup>46</sup> zugeordnet werden. Die

<sup>46</sup> Zu den Einzelsynthese-Verfahren zählen kompensatorische MADM-Verfahren (eng. *Multi Attribute Decision Making*) nach amerikanischem Vorbild. Klassische MADM-Ansätze nach der amerikanischen Schule gehen

Eingangsgrößen – Erkennungsleistung  $P_i$ , Verbrauch unterschiedlicher Ressourcen  $R_i$  – sind hierbei explizit auf die Wertebereich  $P_i \in [0; 1]$  und  $R_i \in [0; 1]$  normiert.

$$w(P_i, R_i) = \frac{f(P_i)}{r(R_i)} = \frac{P_i^\sigma + \gamma}{R_i^\kappa} \quad (\text{F. 8})$$

Die Form der Gewichtungsfunktion kann durch die Exponenten  $\sigma, \kappa$  gezielt angepasst werden. Dies ist nachfolgend in Abb. 41 für unterschiedliche Parametersets dargestellt:



**Abb. 41:** Anpassung der Kurvenform (Steigung, Krümmung) durch Vorgabe der Exponenten für die Kettenleistung ( $\sigma$ , links) und den Ressourcenverbrauch ( $\kappa$ , rechts).

- Der Verlauf der Bewertungsfunktion ist streng monoton steigend mit zunehmender *Kettenleistung*  $P$  (links in Abb. 41). Die Krümmung ist für Exponenten  $\sigma > 1$  positiv (konvex), wodurch für Ketten mit hoher Leistung ein steiler Anstieg der Bewertung realisiert wird.
- Soll dagegen die Kettenleistung erst beim Erreichen einer Schwellleistung  $P_{min}$  in die Bewertung einbezogen werden, so kann der steile Abfall für geringe Kettenleistungen bei Wahl eines konkaven Verlaufs  $0 < \sigma < 1$  genutzt werden. Für  $P_{min} > 0$  wird zusätzlich eine Verschiebung der Kurve um die geforderte Leistung  $P_{min}$  benötigt.
- Der Verlauf der Bewertungsfunktion ist mit zunehmendem Ressourcenverbrauch stets streng monoton fallend (rechts in Abb. 41). Der exponentielle Abfall der Bewertungsfunktion wird dabei über den Exponenten  $\kappa > 0$  eingestellt.
- Für Werte  $0 < \kappa < 1$  lässt sich moderater Abstieg realisieren.
- Kurven mit  $\kappa \gg 1$  sind durch einen sehr steilen Abstieg gekennzeichnet und können so zur Vorgabe eines angestrebten Soll-Ressourcenverbrauchs  $R_{soll}$  genutzt werden.

---

hierbei von der Annahme aus, dass Entscheidungsträger ihre Präferenzen eindeutig quantifizieren und so jedem Kriterium einer Alternative einen Teilnutzwert zuweisen können. Der Gesamtnutzwert ergibt sich durch Aggregation aus den Teilnutzwerten. Je nach Methode werden bei der Aggregation gewichtete Summen oder Produkte eingesetzt, wodurch einerseits mit einem Informationsverlust sowie eine unerwünschte Kompensation von guten und schlechten Kriterienausprägung auftreten können [Tofa14, WiMu17]. Mit steigender Anzahl der Kriterien wird einerseits die Wahl vergleichbarer Teilnutzwertfunktionen erschwert sowie deren Aggregation undurchschaubar. Aufgrund ihrer leichten Nachvollziehbarkeit und Umsetzbarkeit kommen die klassischen Verfahren weiterhin häufig zum Einsatz, obwohl sie bei der hochdimensionalen MCDA zu unerklärlichen, unpräzisen oder falschen Entscheidungen führen können [LaGS14, MoSS18].



Für Kurven mit  $\kappa > 1$  wird zusätzlich eine Verschiebung um den Soll-Ressourcenverbrauch  $R_{soll}$  benötigt.

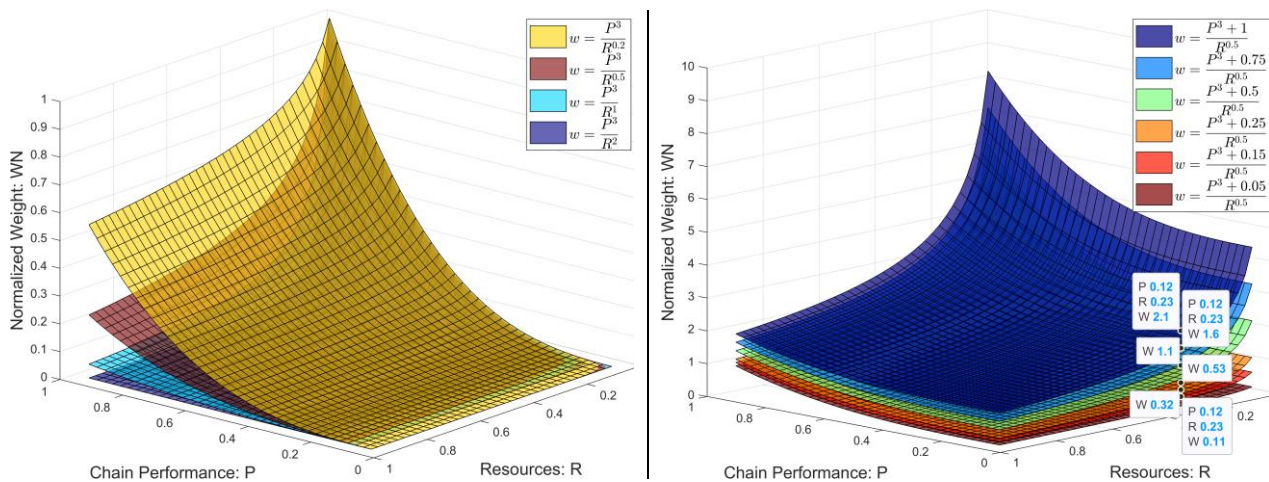
Für eine gemeinsame Darstellung der unterschiedlichen Kurven sowie zur besseren Verständlichkeit und Nachvollziehbarkeit der Kettenbewertung während des Einsatzes wird eine zusätzliche Normierung der Bewertungsfunktion  $w$  auf einen Wertebereich zwischen 0 und 1 (bzw. 0 und 100 %) vorgenommen. Dies umfasst zunächst eine Verschiebung um das globale Minimum der Bewertungsfunktion  $w$ :

$$wo_i = w_i(P_i, R_i) - \min_{i=1, \dots, n} (w_i(P_i, R_i)) \tag{F. 9}$$

Danach erfolgt die Skalierung von  $wo_i$  bzgl. des globalen Maximums von  $wo_i$ :

$$wn_i = \frac{wo_i(P_i, R_i)}{\max_{i=1, \dots, n} wo_i(P_i, R_i)} \tag{F. 10}$$

Die ideale Kette hat somit einen normierten Wert von 1 (Zielerreichung von 100%), wohingegen die ungünstigste Kette einen Wert von 0 (Zielerreichung von 0%) aufweist (vgl. Abb. 42 rechts, sowie Abb. 43). In Anlehnung an die Berechnung der Effizienz wird dabei die Erkennungsleistung  $P_i$  ins Verhältnis zum Ressourcenverbrauch  $R_i$  gesetzt (Abb. 42 links).




**Abb. 42:** Zur multikriteriellen Bewertung wird die Erkennungsleistung  $P_i$  ins Verhältnis zum Ressourcenverbrauch  $R_i$  gesetzt (links).

Je nach Vorgabe des Verhältnis-Parameters  $\gamma$  können unterschiedliche Bewertungsfunktion als Grundlage für die Rangfolgeerstellung der besten Ketten ausgewählt werden.

### 7.2.3 Eigenschaften der eingesetzten Bewertungsfunktionen

Folgende Fälle lassen sich gemäß den Parametern und den Formen der Bewertungsfunktionen aus Abb. 43 ableiten:



**Abb. 43:** Feinjustierung der Bewertungsfunktion. Für die Bewertung und damit für die Kettenrangfolge kann durch  $\gamma$  (F. 8) das relative Verhältnis der Höhe der Bewertungsfunktion am linken Rand (Kettenleistung) und am rechten Rand (Ressourcen) beeinflusst werden. Hierdurch ergeben sich die beschriebenen Anwendungsfälle a) – c).

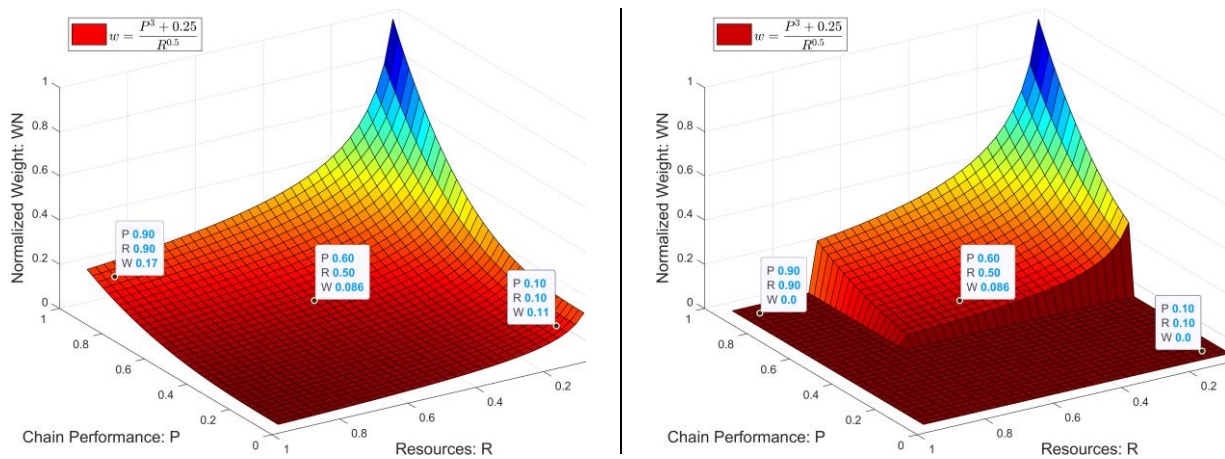
- $\gamma \leq 0.2$  (*dunkel/hellrot*): Die zuverlässigsten Ketten mit hoher Leistung werden bevorzugt. Der Einfluss des Ressourcenverbrauchs wird zwar berücksichtigt, spielt aber im Vergleich zur Kettenleistung eine untergeordnete Rolle bei der Rangfolgeerstellung.
- $0.2 < \gamma < 0.7$  (*gelb-grün*): Universelle, faire Bewertung, hier werden zuverlässigen Ketten mit moderatem Ressourcenverbrauch bevorzugt.
- $\gamma \geq 0.7$  (*hell-/dunkelblau*): Ressourcensparende Ketten werden bevorzugt. Die Kettenleistung wird berücksichtigt, spielt aber eine untergeordnete Rolle.

Wie im Abschnitt 5.1 erläutert wurde, soll die Vorgabe von  $\gamma$  entweder manuell durch den Operateur oder automatisch durch den *Processing Coordinator* getroffen werden, um einen Kompromiss aus den Anforderungen aufgrund der Mission bzw. Situation sowie der Verfügbarkeit an Ressourcen vorgeben bzw. berechnen zu können.

#### 7.2.4 Grenzwertvorgaben zur Vorauswahl von Ketten

Zusätzlich ist eine Vorfilterung zur Vorauswahl der Ketten anhand von relativen oder absoluten Kriterien-Grenzwerten vorgesehen:

- Hierdurch können einerseits Anforderungen, wie ein maximaler Ressourcenverbrauch oder eine nicht zu unterschreitende Kettenleistung direkt vorgegeben werden.
- Andererseits lassen sich so unerwünschte Effekte an den Rändern (Abb. 44) verhindern.



**Abb. 44:** Vorgabe von Anspruchsniveaus dient zur Einhaltung von Randbedingungen sowie zur Reduktion unerwünschter Randeffekte.

Diese Vorfilterung kann entweder während Kettenbewertung oder bereits während der Kettenkoordination stattfinden:

- Wie im Kettenmanagement (Abschnitt 7.1) beschrieben wurde, werden hierzu beim Veröffentlichen von Auktionen neben *Capability-Constraints* (Typ, Sensor, Location) gezielt Anspruchsniveaus für jedes Kriterium in der Taskbeschreibung definiert (*Satisficing* in Abb. 39).
- Können diese Mindest- oder Höchstwerte von einer Kette nicht eingehalten werden, so gibt diese kein Angebot ab und nimmt folglich auch nicht an der Rangfolgebestimmung (Winner-Chain-Determination) teil.

Dieser Mechanismus erhöht die Nachvollziehbarkeit und reduziert gleichzeitig den Rechenaufwand und damit Overhead während der Rangfolgeberechnung bzw. -erstellung.

### 7.3 Vorabvalidierung systemischer Funktionalitäten

Bevor der Mehrwert des SPMS-Konzeptes im Rahmen des Anwendungsszenarios untersucht wird, sollen gemäß dem Evaluierungskonzept (Abschnitt 8.1) sowohl

- Systemische und operationelle Anforderungen wie Robustheit, Ausfallsicherheit, Erweiterbarkeit, Transparenz und Eingriffsmöglichkeiten sowie
- das Fähigkeitenkonzept für das Zusammenspiel zwischen MMS/Operator-SPMS

sichergestellt werden.

Anhand konkreter Testfälle wurden Teilsysteme des SPMS-Konzeptes bereits während der Entwicklung auf Funktionalität und Probleme hin überprüft. Diese Vorabvalidierung sollte sicherstellen, dass Daten, Schnittstellen und Methoden für die umfassendere Konzeptvalidierung (Kapitel 9) geeignet sind.

Dabei stand nicht die Detektionsleistung der Ketten, sondern vielmehr die Validierung der Koordination und Rangfolgeerstellung der Ketten im Fokus. Die Testfälle umfassten daher

- das Umschalten zwischen Ketten, das Deaktivieren von Ketten und die Integration neuer Ketten sowie
- die Darstellung der Wahrnehmungsfähigkeiten und Integration der Wahrnehmungsfähigkeiten in eine wegpunktbasierte Führung eines UAVs.

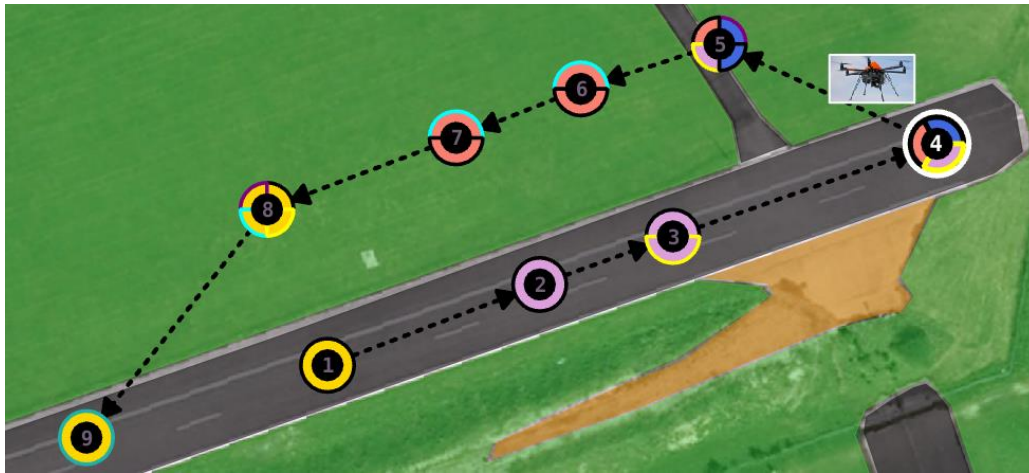
Zur Abbildung der Testfälle und deren Evaluierung wurde ein Kettensimulator und ein zweckgebundenes MMS entwickelt (Abb. 47), welches die folgenden Funktionalitäten bietet:

- Wegpunkte können mit Hilfe des MMS mit Wahrnehmungsaufgaben (Personen-/Fahrzeugdetektion, Sensortyp und Einsatzort) versehen werden.
- Ein Test-Setup von Ketten kann im Kettensimulator geladen werden (Abb. 46). Dies umfasst einerseits reale Ketten mit modellierten Leistungsvorhersagen (BN) und andererseits reine Test-Ketten mit frei wählbarem Aufgabentyp, Sensor, Leistung und Ressourcenverbrauch.
- Die Kriterien der multikriteriellen Kettenauswahl (Winner-Chain-Determination) können während des Testlaufs verändert werden, um so unterschiedliche Rangfolgen der Ketten (*Detektionsleistung* ausschlaggebend über *ausgewogen bis Ressourcenverbrauch* minimierend) zu prüfen.
- Zur Überprüfung des Umschaltverhaltens werden die angefragten Wahrnehmungsaufgaben (Auktionen des *Perzeption-Solvers*), die zeitliche Reihenfolge der Angebote der Ketten (voraussichtliche Kettenleistung und Ressourcenverbrauch) und die Rangfolge der Besten-Ketten (*Processing-Coordinator*) protokolliert.

Nach Vorgabe einer Testmission (Abb. 45) und Wahl eines angepassten Ketten-Setups, wurde so eine umfängliche Testumgebung aufgebaut. Die Testmission ist in Abb. 45 dargestellt.

Einzelne Wegpunkte sind mit einer mehreren Wahrnehmungsaufgaben verknüpft. Diese Suche nach den besten Ketten (Auktionen, Abschnitt 7.1.1) kann dabei sequenziell oder parallel stattfinden:

- *Sequenzielle* Ausführung: Aufgaben bzw. Fähigkeiten können manuell oder automatisch während des Fluges aktualisiert werden. Ein Beispiel ist WP1. Im Ablaufdiagramm (Abb. 48) sind dementsprechend drei sequenzielle Auktionen für WP1 zu sehen.
- *Parallele* Ausführung: Mehrere Wahrnehmungsaufgaben sind einem Wegpunkt zugordnet. Im Flugplan des MMS (Abb. 45) ist hierfür eine Unterteilung der WP-Kreissegmente vorgesehen. Dementsprechend sind auch mehrere parallele Aufgaben im Ablaufdiagramm (Abb. 48) ersichtlich. So sollen bei WP4 jeweils die besten Ketten für die Hindernis-, Personen- und Fahrzeugdetektion gefunden und ausgeführt werden.



**Abb. 45:** Testablauf zur Validierung systemischer Anforderungen: Jeder Wegpunkt ist hierbei mit mindestens einer konkreten Wahrnehmungsaufgabe verbunden. WP7 stoppt sämtliche aktive Ketten stoppen. Die Wahrnehmungsaufgaben sind über Farben der Kreissegmente dargestellt: gelb = Request-Capabilities, pink = Obstacle-Detection, rot = Person-Detection, blau = Vehicle-Detection. Die Vorgabe eines Sensor-Typs wird ebenfalls untersucht. Der Sensortyp ist anhand des farblichen Randes der Wegpunkte ersichtlich: schwarz = Any-Sensor, gelb = LIDAR, violett = LWIR, cyan = EO, türkis = EO-Wide.

Während der Entwicklung wurden mehrere Testreihen durchgeführt. Bei ersten Testdurchläufen traten noch Fehler beispielsweise beim Zerlegen und Umschalten von Wahrnehmungsauktionen und -aufgaben oder bei der Modellierung der Kettenleistung auf. Die Fehlerursachen wurden dabei identifiziert und entsprechende Korrekturmaßnahmen zur Behebung von Design- und Programmierfehlern konnten erfolgreich umgesetzt werden.

Der finale und erfolgreiche Testablauf des Test-Szenarios (Abb. 45) wurde dabei protokolliert. Die Ergebnisse – kausalrichtige Umschaltvorgänge zwischen Ketten – sind im Sequenzdiagramm in Abb. 48 dargestellt. Die einzelnen Testfälle umfassten die folgenden Teile:

- Initial wurde nur ein Teil-Setup von Ketten (EO-, LIDAR- & Test-Ketten) geladen.
- Für die Kettenauswahl-Funktion wurde zunächst der Ressourcen-Verbrauch stärker gewichtet als die *Detektionsleistung*.
- Als Referenz-Flugversuch wurde ein Wintertag am Morgen gewählt, so dass sowohl EO- als auch IR-Sensor prinzipiell eingesetzt werden könnten (2014-02-27 [11:13:27]).

#### 1. WP = Request-Capabilities

1. Es wird nach *einer* besten Kette mit *beliebigem* Typ und *beliebigem* Sensor gesucht.
  - ✓ Alle geladenen/aktivierten Ketten nehmen an der Auktion teil.
  - ✓ Test-Kette (TEST\_ResLow-TrustMed-AllCap) mit akzeptabler Leistung und sehr geringem Verbrauch gewinnt.
2. IR-Sensor ist verfügbar bzw. repariert, die IR-Ketten werden geladen & Winner-Chain-Funktion ist nun ausbalanciert, d.h. sowohl Leistung als auch Ressourcen-Verbrauch sollen berücksichtigt werden.
  - ✓ Auch die IR-Ketten nehmen an Auktion teil



- ✓ Automatisches Umschalten der Ketten von TEST\_ResLow-TrustMed-AllCap auf EO-Vehicle-Tiny
- 3. Kettenauswahl-Funktion wird so geändert, dass die Kettenleistung stärker gewichtet wird als der Ressourcenverbrauch:
  - ✓ Automatisches Umschalten von EO-Vehicle-Tiny auf IR-Person-Cold
- 2. WP = Obstacle (Any)
  1. Es wird die beste Kette gesucht, die Hindernisse mit beliebigem Sensor erkennt.
    - ✓ Nur die Ketten TEST\_ResLow-TrustMed-AllCap und LIDAR-Obstacle kommen in Frage.
    - ✓ Test-Kette TEST\_ResLow-TrustMed-AllCap wird ausgewählt.
- 3. WP = Obstacle (Any + LIDAR)
  1. Es wird die beste Kette gesucht, die Hindernisse mit beliebigem Sensor erkennt.
    - ✓ Test-Kette TEST\_ResLow-TrustMed-AllCap bleibt aktiv
  2. Zusätzlich und gleichzeitig wird die beste Kette mit LIDAR-Sensor gesucht, die Hindernisse erkennt.
    - ✓ LIDAR-Obstacle wird ausgewählt und gestartet.
- Test-Kette (TEST\_ResLow-TrustMed-AllCap) wird vom Nutzer entladen oder deaktiviert, weil sie z.B. als zu fehlerhaft betrachtet wird.
- 4. WP = Multi-Task (Obstacle = LIDAR, Vehicle + Person = Any-Sensor)
  1. Mehrere unterschiedliche Aufgabentypen (Hindernis-, Personen- und Fahrzeugdetektion) sollen gleichzeitig ausgeführt werden, wobei jeweils nur die beste Kette ausgewählt werden soll.
    - ✓ Je nach Aufgabentyp nehmen unterschiedliche Ketten zeitgleich an mehreren Auktionen teil.
    - ✓ LIDAR-Obstacle (durch Vorgabe von Sensor=LIDAR)
    - ✓ IR-Person-Cold und IR-Vehicle-Generic gewinnen.
- 5. WP = Multi-Task (Obstacle + Vehicle + Person = Any-Sensor parallel Vehicle = IR)
  1. Mehrere unterschiedliche Auktionen mit Aufgabentyp (Hindernis-, Personen- und Fahrzeugdetektion) und ohne Sensorvorgabe sowie zusätzlich Fahrzeugdetektion mit IR-Vorgabe werden angefragt.
    - ✓ Straße: EO-Vehicle-Generic, IR-Person-Cold, LIDAR-Obstacle.
    - ✓ Wiese: LIDAR-Obstacle, IR-Person-Cold, EO-Vehicle-Tiny gewinnen.
    - ✓ Parallel bleibt IR-Vehicle-Generic aktiv. Sie gewinnt die zusätzliche Auktion (Fahrzeugdetektion mit IR-Sensor-Vorgabe).
- 6. WP = Multi-Task + mehrere, beste Ketten pro Auktion

1. Es sollen jeweils die beste Personen-Kette für einen beliebigen Sensor und die beste Personen-Kette für den EO-Sensor gesucht werden.
  - ✓ Person-IR-Cold und Person-EO-Tiny werden entsprechend der ausbalancierten Kettenauswahl-Funktion ausgewählt.
2. Anzahl der Winner-Chains pro Task wird erhöht (1-3), u.a. zur Absicherung der Ergebnisse oder bei sicherheitsrelevanten Einsätzen:
  - ✓ Für jede Aufgabe werden zusätzlich jeweils die nächstbesten Ketten gestartet (Orange in Abb. 48).
7. WP = Multi-Task + Umwelt-, Jahres-/Tageszeitänderungen durch Flugversuchswechsel: Einflüsse geänderter Umweltbedingungen sollen über geänderte, vorhergesagte Leistungen sollen zu einer Änderung der Kettenreihe führen. Ausgangspunkt ist sind Tasks gemäß WP6:
  1. Tageszeitwechsel (Dämmerung): 2014-02-27 [17:35:46]
    - ✓ Vorhergesagte Leistungen ändern sich und führen zu einer neuen Kettenreihenfolge: EO-Tiny-Night ist nun beste Kette.
  2. Jahreszeitwechsel (Heiß-Gras): 2014-07-04 [15:48:23]
    - ✓ Leistungsfähigkeit von IR-Ketten über Gras (WP7) bricht ein, Leistungen von EO-Ketten sind dagegen nun wieder gut oder sehr gut.
8. WP = Request-Capabilities
  1. Gleichzeitige Suche nach den besten Ketten sensorunabhängig und für jeden Sensor allein betrachtet.
    - ✓ Erkennung bereits aktiver Ketten: Keine Kette wird doppelt gestartet.
    - ✓ WP- und taskübergreifend bleiben bereits aktive Ketten aktiv, solange sie wiederum Winner-Chains sind.
    - ✓ Eine Aufgabe beendet keine Ketten anderer Auktionen bzw. Aufgaben.
  2. Anzahl der Winner-Chains = 1
    - ✓ Für jede Auktion werden die nächstbesten Ketten beendet.
9. WP = Skalierbarkeit
  1. Es wird keine passende (Bild-)/Verarbeitungskette für den neuen Sensortyp und die Perspektive gefunden.
    - ✓ Nur Sensor-Streaming ist aktiv.
  2. Neue Ketten werden zur Laufzeit geladen (COCO-yolo-CSP):
    - ✓ Rangfolge wird geändert

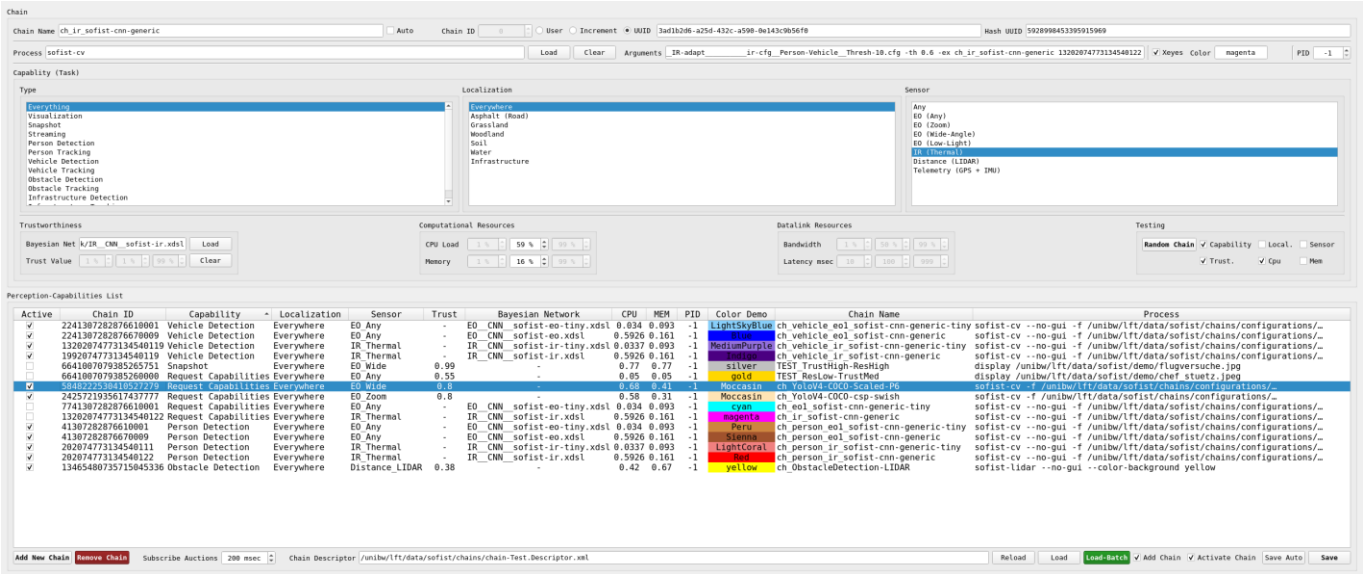


Abb. 46: Im Kettensimulator können bereits implementierte Ketten sowie reine „Test-Ketten“ geladen, deaktiviert bzw. entfernt und konfiguriert (BNs oder feste Vorgaben von Leistung und Ressourcenverbrauch) werden.

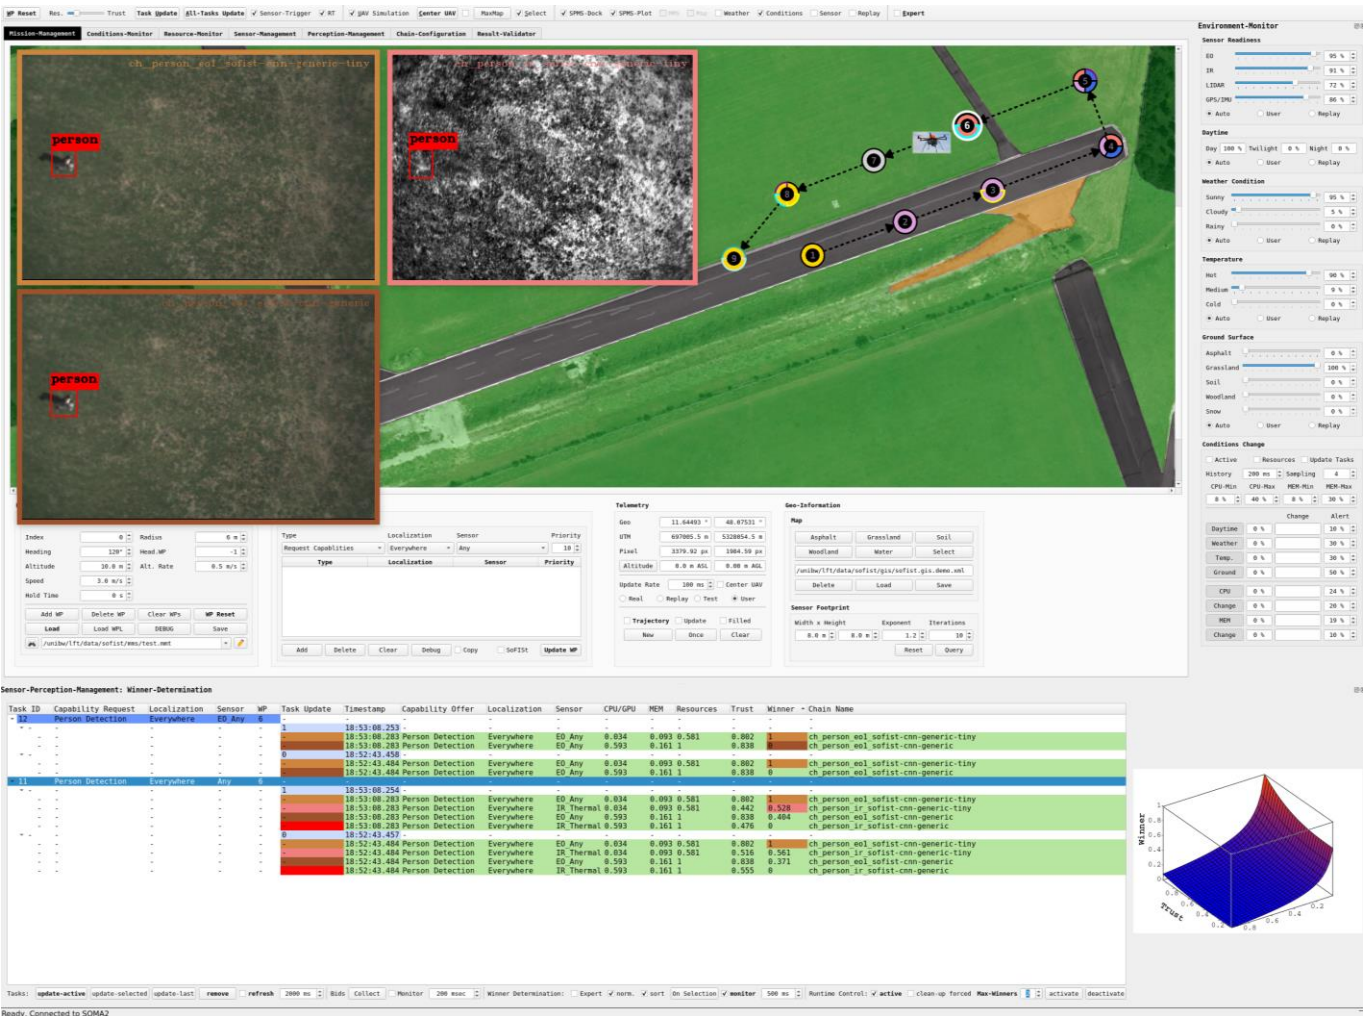
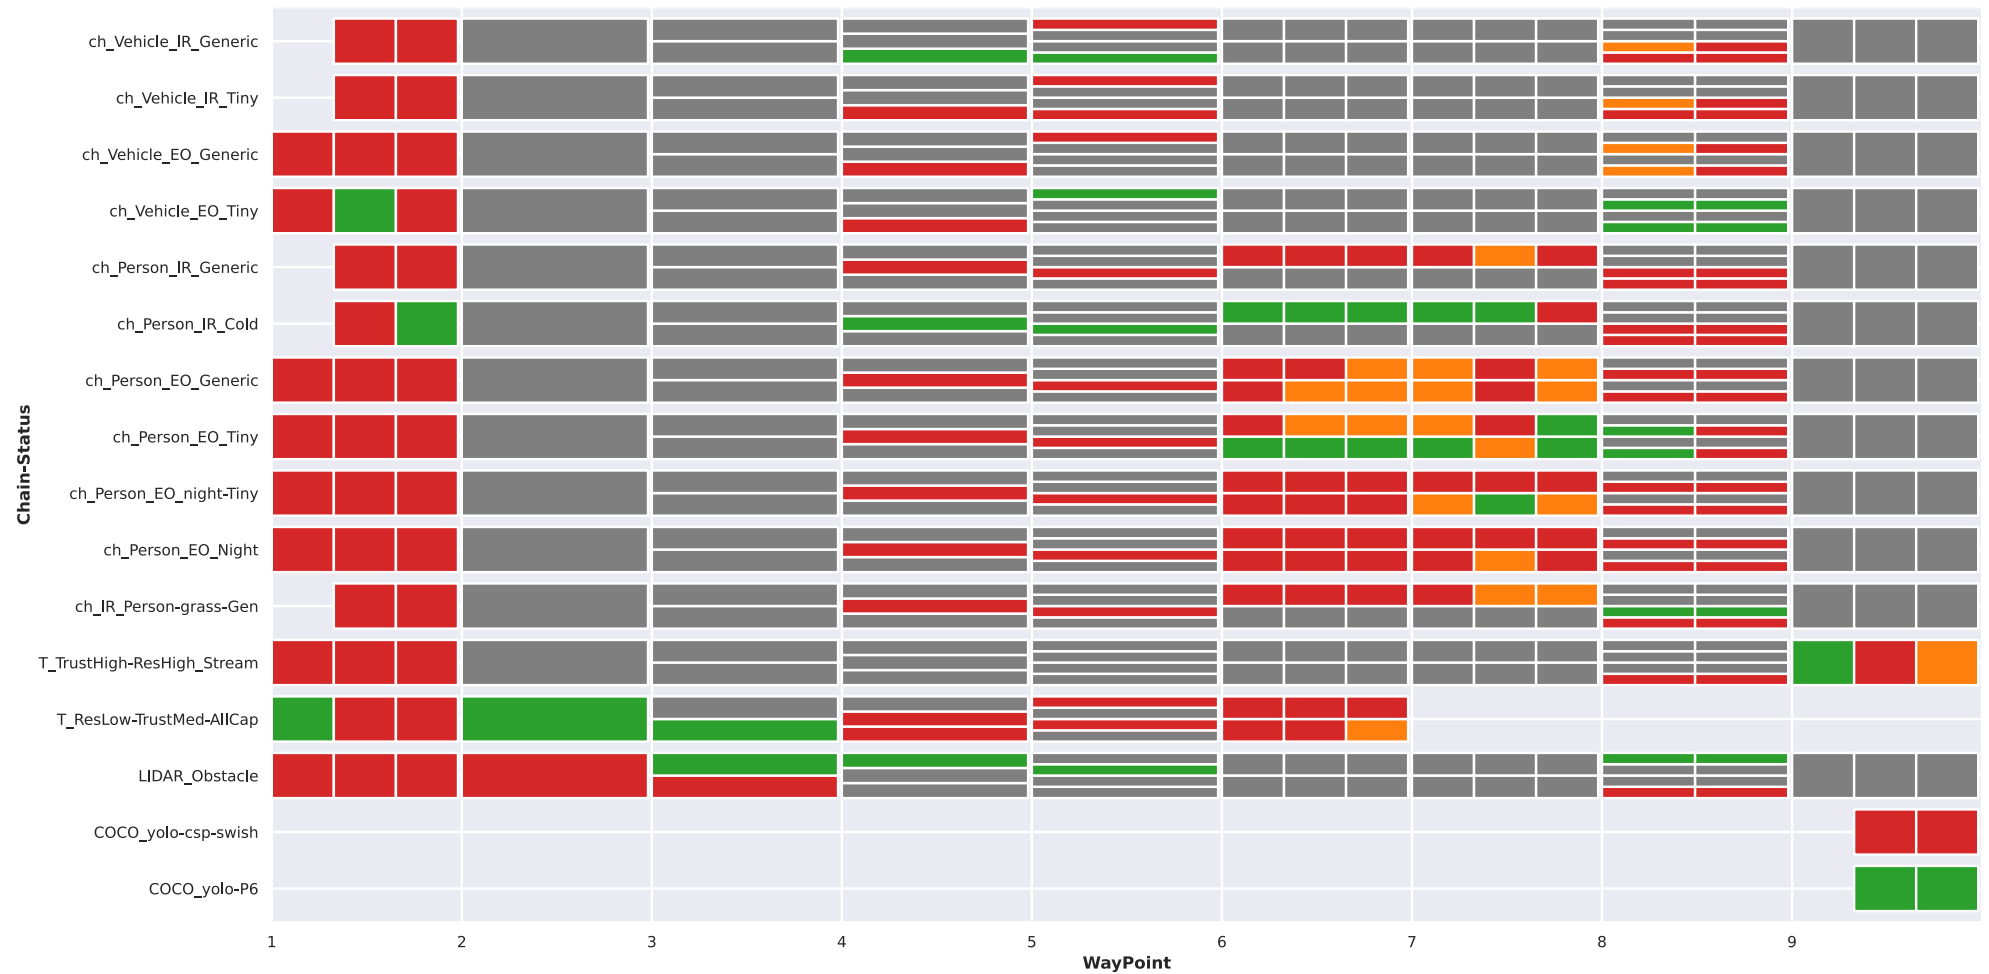


Abb. 47: MMS mit Wahrnehmungsaufgaben (oben), Visualisierung der Kettenauswahl (unten), aktivierte Ketten (oben-links), Wetter-/Umweltzustände (rechts) und Winner-Determination Funktion (unten-rechts).





**Abb. 48:** Ablaufdiagramm zur Kontrolle systemischer Anforderungen gemäß Test-Szenario aus **Abb. 45:**

Auktionen können *sequenziell* oder *parallel* stattfinden:

- Hell-Blau:** Kette ist inaktiv bzw. nicht geladen,
- Dunkel-Grau:** Kette ist geladen, aber keine Übereinstimmung mit Typ bzw. Sensor
- Grün:** Kette ist geeignet und gleichzeitig die beste Kette für den Aufgabentyp,
- Orange:** Kette ist geeignet und nächstbeste Kette und wird parallel gestartet
- Rot:** Kette wäre geeignet, aber ist keine Winner-Kette.



## 8. Experiment und Flugversuche

Das Evaluierungskonzept und die Untersuchungsgegenstände dienen zur Beantwortung der Forschungsfragen (Abschnitt 4.2). Sie sind damit die Grundlage der durchgeführten Experimente und die Wegweiser einer zielführenden Auswertung.

Anhand des Evaluierungskonzeptes (Abschnitt 8.1) sollen sich die Ziele, Anforderungen und Randbedingungen des Systementwurfs im Zuge realer Flugversuche überprüfen lassen. Dieses Kapitel beschreibt die hierfür notwendigen Phasen: Versuchsplanung und -vorbereitung sowie die Durchführung der Flugversuche.

Während der Versuchsvorbereitung wurden Flugversuche im Rahmen des Unfallszenarios geplant (Abschnitt 8.2), ein Versuchsträger – bestehend aus dem Fluggerät Okto-XL (Abschnitt 8.3.1) und der Sensornutzlast (SOMA, Abschnitt 8.3.2) – aufgebaut und Bildverarbeitungsketten implementiert (Abschnitt 8.4).

Die Durchführung der Flugversuche diene zur Evaluierung der Grundannahme einer situations- und umweltoptimalen Anpassungsmöglichkeit vorkonfigurierter Ketten (Abschnitt 9.2) sowie zur Bestimmung eines möglichen Mehrwerts durch Einsatz des SPMS (Abschnitt 9.3). Hierfür wurden Sensordaten hoher Variabilität<sup>47</sup> benötigt, weshalb das Anwendungsszenario zwischen Frühjahr 2013 und Winter 2021 mehrmals wiederholt wurde.

### 8.1 Evaluierungskonzept

Wie in der Zielsetzung der Arbeit (Kapitel 4) definiert, soll eine prototypische Umsetzung SPMS-Konzeptes unter dynamischen Umweltbedingungen evaluiert werden.

#### 8.1.1 Prüfbarkeitsfunktionalitäten

Zur Ableitung prüfbarer, system- und konzeptrelevanter (Teil-)Funktionalitäten wurden die Anforderungen an ein Systemkonzept gemäß Abschnitt 4.1 berücksichtigt:

- a) Das *Fähigkeiten-Konzept* soll das *Zusammenspiel zwischen MMS-SPMS* ermöglichen. Wahrnehmungsfähigkeiten sollen durch ein Missionsmanagement während des Fluges einzeln oder gleichzeitig abrufbar sein. Zur Erfüllung des Auftrags können daher unterschiedliche Wahrnehmungsfähigkeiten wie Personen-, Fahrzeug- oder Hinderniserkennung erforderlich sein.
- b) *Spezialisierte Ketten* sollen sich explizit für schwierige Umweltkonstellationen zusammenstellen, trainieren und *zielgerichtet und gewinnbringend einsetzen* lassen.
- c) Eine *Modellierung zur Abschätzung der jeweiligen Kettenleistung* in Abhängigkeit aktueller Umgebungsparameter ist die Voraussetzung für den zielgerechten Einsatz spezialisierter Ketten. Das SPMS soll hierfür die jeweiligen Modelle (BN) auswerten und eine aktuelle Rangfolge geeigneter/an Umgebung adaptierter Ketten erstellen.

---

<sup>47</sup> Dementsprechend wurden unterschiedliche Jahres-/Tageszeiten, Witterungs-/Umweltzuständen (Beleuchtung, Schatten, Temperatur) und topografischen Bedingungen (Asphalt/Straße, Gras) berücksichtigt.

Hierdurch sollen Wahrnehmungsfähigkeiten auch bei unterschiedlichen Jahres- bzw. Tageszeiten, Wetterlagen sowie für diverse Unter- und Hintergründe zuverlässig ermöglicht werden.

- d) Die *Rangfolgeerstellung* geeigneter Ketten *mehrere Kriterien* berücksichtigen. Die Bewertung von Sensoren und Algorithmen soll daher nicht nur die Kettenleistung, sondern auch die zur Verfügung stehenden Ressourcen einschließen. Hierdurch soll eine gleichzeitige Bearbeitung mehrerer Wahrnehmungsaufgaben auch bei eingeschränkten Ressourcen realisiert werden.

Hierbei sollen auch *systemische Anforderungen* wie Ausfallsicherheit, Robustheit, Erweiterbarkeit sowie Verständlichkeit<sup>48</sup> verifiziert werden.

### 8.1.2 Untersuchungsgegenstände

Untersuchungsgegenstände sind eine gängige Methode zur Validierung technischer Systeme [Grad16, KBSF20, WiHW12]. Sie sollen den Fokus und Rahmen für die Bewertung der Funktionsfähigkeit, Leistung und Zuverlässigkeit technischer Systeme vorgeben, damit die Erfüllung von Anforderungen und Erwartungen gewährleistet<sup>49</sup> ist.

Um eine transparente, messbare, aber dennoch effiziente Überprüfung der prototypischen Implementierung des SPMS-Konzepts unter Berücksichtigung der Anforderungen aus Abschnitt 4.1 zu gewährleisten, wird ein dreistufiger Evaluierungsprozess angewendet, der sich auf die nachstehenden Hauptuntersuchungsgegenstände konzentriert:

- I. Vorabvalidierung<sup>50</sup> systemischer Funktionalitäten (Abschnitt 7.3)
- II. Untersuchungen zur Anpassungsmöglichkeit von Ketten (Abschnitt 9.2)
- III. Mehrwert einer SPMS-Umsetzung unter realistischen Bedingungen (Abschnitt 9.3)

Diese Aufteilung und Reihenfolge wurden gewählt, um spezifische Eigenschaften separiert, reproduzierbar und unter reduzierten Wechselwirkungen testen und auswerten zu können<sup>51</sup>.

Zur Ableitung konkreter Testfälle wurden weitere Detaillierungen vorgenommen. Neben freien Variablen wie Umgebungs-/Wetterzustände, Sensoren und Algorithmen werden der Abstraktionsgrad, Randbedingungen und die verwendete Testumgebung unterschieden. Die einzelnen Stufen sind in Tabelle 2 zusammengefasst.

---

<sup>48</sup> Transparenz und Eingriffsmöglichkeiten durch den Payload-Operateur

<sup>49</sup> unter den folgenden Gesichtspunkten Qualitätssicherung, Fehlererkennung, Sicherheit, Optimierung, Compliance und Wirtschaftlichkeit

<sup>50</sup> Diese Vorabvalidierung sollte sicherzustellen, dass Daten, Schnittstellen und Methoden für die umfassendere Konzept-Validierung (Kap. 9) geeignet sind. In der Software-Entwicklung werden häufig Alpha- oder Beta-Version oder Teilfunktionen vorab getestet. Durch diese Vorabvalidierung sollten potenzielle Probleme oder Fehler frühzeitig identifiziert und behoben werden.

<sup>51</sup> vgl. Gütekriterien sicherheitsrelevanter Systeme nach [WiHW12]: Objektivität, Reliabilität und Validität.

Der finale *Hauptuntersuchungsgegenstand* – Mehrwert einer SPMS-Umsetzung unter realistischen Bedingungen – wird anhand einer Beispielanwendung (Unfallszenario, Abb. 49) und mit den gewählten Methoden (Kettenmodellierung mit *BNs*, *Marktbasierte Koordination*) näher untersucht werden.

Der Mehrwert wird aus der Differenz zwischen SPMS-Gesamtleistung und der Leistung generischer Ketten unter schwierigen Umweltbedingungen und beim Ausfall von Sensoren ermittelt. Hierfür werden die folgenden Betriebszustände detailliert untersucht:

- 1) *Idealer Betrieb: Uneingeschränkt und mit beliebigen Ressourcen:*
  - a. Die resultierende SPMS-Erkennungsleistung über mehrere Flugversuche soll deutlich besser sein als die Kettenleistung generischer Ketten.
  - b. Für jeden Flugversuch/Tag darf die SPMS-Leistung nur marginale Abweichung zur besten Kette an diesem Tag aufzeigen.
- 2) *Fail-Operational-Betrieb: Eingeschränkt mit beliebigen Ressourcen*
  - a. Bei Ausfall oder Verschlechterung von Komponenten soll das SPMS eine weiterhin akzeptable Leistung aufweisen. Durch einen systemischen Fehler soll das SPMS eine Teil-Funktionalität aufrechterhalten können.
- 3) *Betrieb bei Ressourcenknappheit oder Konflikten:*
  - a. Welcher Mehrwehrt wird bei Vorgabe weiterer Optimierungsgrößen (Ressourcenverbrauch: Rechenleistung & Speicherbedarf) erzielt?

Der UAV-Einsatz insbesondere der optimierte Sensoreinsatz und dessen computergestützte Datenauswertung soll dabei automatisiert/autonom und echtzeitfähig sein, d.h. es werden nach der Missionsplanung und dem Laden der Ketten, kein oder nur ein minimaler, überschaubarer Nutzerinput benötigt.

**Tabelle 2:** Evaluierungskonzept: Auflistung der Untersuchungsgegenstände mit folgender Nomenklatur:

V = Variable Komponenten/Zustände, F = Feste/Fixe/Statistische Zustände, X = eingesetzte Komponenten, Q = Qualitative Auswertung/Sichtung, A = quantitative Auswertung


Untersuchungsgegenstand		Variablen / Ziele				Umgebungsparameter				Resourcen			Abstraktionsgrad Komponenten			Testbett			Ziel		Beschreibung
		Szene	Tag / Jahr	Untergrund	Wetter / Licht	CPU-Last	Speicher	Sensoren	Algorithmen	Modellierung	Koordination	MMS	Flugversuch	Simulator	Leistung	Funktion					
<b>I</b>	<b>Vorabvalidierung systemischer Funktionalitäten</b>																				
<b>I.A</b>	Kettenmodellierung mit BN	F	F	F	F	-	-	V	V	X	-	-	X	-	A	-				Qualität der Modelle	
<b>I.B</b>	Koordination von Ketten																				
<b>I.B.1</b>	Auswahlprozess & Bewertung	V	V	V	V	V	V	F	F	-	X	-	-	X	-	A				Koordination, Rangfolge	
<b>I.B.2</b>	Ausfall von Sensoren/Ketten	-	-	-	-	-	-	V	V	-	X	-	-	X	-	Q				Robustheit, verbleibende Leistung	
<b>I.B.3</b>	Erweiterbarkeit um Sensoren/Ketten	-	-	-	-	-	-	V	V	-	X	-	-	X	-	Q				Möglichkeit und Aufwand	
<b>II.C</b>	Tasking durch MMS/Operateur	-	-	-	-	-	-	V	V	-	X	X	-	X	-	Q				Fähigkeitenkonzept, Transparenz & Eingriff	
<b>II</b>	<b>Anpassungsmöglichkeit von Ketten</b>																				
<b>II.A</b>	Umwelt, Umgebung, Jahres-/Tageszeit	V	V	V	V	-	-	V	V	-	-	-	X	-	Q	-				Leistungsbestimmung	
<b>II.B</b>	Ressourcen	F	F	F	F	V	V	V	V	-	-	-	X	-	Q	-				Leistungsbestimmung	
<b>III</b>	<b>Mehrwert einer SPMS-Umsetzung unter realistischen Bedingungen</b>	V	V	V	V	F	F	F	F	X	X	X	X	-	A	Q				Leistungssteigerung bei unterschiedlichen Jahres-/ Tageszeiten,	

## 8.2 Versuchsplanung des Beispielszenarios

Das Ziel der Versuchsvorbereitung war es, eine beispielhafte Durchführbarkeit und Wiederholbarkeit der Flugversuche zu erreichen. Dabei war es wichtig, dass die Untersuchungsgegenstände aus Abschnitt 8.1 repräsentativ und wiederholbar abgebildet und ausgewertet werden können.

Die Vorbereitung der Versuche umfasste die Entwicklung der Versuchsträger, die Integration und Konfiguration der Sensornutzlast, die Implementierung der Wahrnehmungsketten, sowie die Erstellung des Szenarios und die darauf basierende Planung von Flugversuchen.

Um den Aufwand zu minimieren, eine zügige Versuchsvorbereitung zu ermöglichen und gleichzeitig Zulassungsbeschränkungen sowie potenzielle Gefahren zu reduzieren, war vorgesehen, die Realflugversuche auf dem Testgelände der UniBwM in Neubiberg durchzuführen. Hierfür wurden der Ablauf und die Dimensionen des Anwendungsszenarios an die Bedingungen des Testgeländes angepasst. Eine detaillierte Skizze und Ortsbeschreibung des Beispielszenarios sind in Abb. 49 dargestellt und erläutert.



**Abb. 49:** Ablauf und Ort des gewählten Beispielszenarios auf dem Testgelände der UniBwM: (1, blau) Start des UAVs, (2) Verkehr überwachen, (3) Unfallstelle finden (Autos und Menschen auf Straße), (4, violett) Suche nach möglichen verwundeten/Hilfebedürftigen (Personensuche, Live-Streaming) und (5, gelb) Hinderniserkennung zur gezielten Disposition/Routenführung von Rettungskräften (rot).

Das Beispielszenario umfasst die folgenden Teilaufgaben:

### 1. Start des UAVs

2. *Verkehrsüberwachung*: Hierbei sollen Fahrzeuge (Autos und Klein-/Laster) auf der Straße erkannt/beobachtet werden.
3. *Unfallstelle finden*: Für eine Unfallstelle wird hierbei angenommen, dass sich Fahrzeuge als auch Menschen auf Straße befinden oder Fahrzeuge quer zur Fahrtrichtung stehen.
4. *Verwundete oder hilfebedürftige Personen finden*: Eine Personensuche soll dabei auch in der Nähe (u.a. Wiese) einer möglichen Unfallstelle (Straße) stattfinden.
5. *Routenführung von Rettungskräften*: Hierbei soll auf einer alternativen Route nach möglichen Hindernissen oder einem Stau gesucht werden.

Hieraus leiten sich direkt die nötigen Wahrnehmungs- und Sensorfähigkeiten und somit die zu implementierenden Wahrnehmungsfähigkeiten ab (Abschnitt 8.4):

- *Vorder- und Untergrund*: Hierdurch sollen einerseits Straßen und das Geländearten wie Wiesen/Wälder erkannt und im Sinne des SPMS-Konzeptes genutzt werden.
- *Objekterkennung*: Dies schließt die Erkennung von Personen- und Fahrzeugen ein.
- *Hinderniserkennung*: Die Hinderniserkennung dient im Szenario u.a. zur gezielten Routenführung der Rettungskräfte.

Um eine Variation der Landschaft, der Untergrundtemperatur und insbesondere der Wetter- und Beleuchtungsbedingungen zu erreichen, wurden die Flugkampagnen über den Tag verteilt und zu unterschiedlichen Jahreszeiten geplant.

Die Routen aller Flugkampagnen sind in Tabelle 5 zusammengefasst. Zur Validierung wurden dabei gesonderte Flugversuche mit hohen Variationen der Tages- und Jahreszeiten, Wetter- und Temperaturbedingungen durchgeführt. Diese Referenzflüge sind zusätzlich detaillierter in Tabelle 4 aufgelistet.

### 8.3 Flugversuchsträger

Für die Erprobung im Realflug wurde ein geeignetes Fluggerät und eine modulare Sensor-Rechner-Nutzlast konstruiert, integriert und getestet.

Auswahl und Anpassung des Versuchsträgers mussten dem Beispielszenarios, dem Testgelände und den Untersuchungsgegenstände genüge leisten. Dementsprechend wurden die Anforderungen an den resultierenden Versuchsträger wie folgt vorab abgeleitet:

- a) *Wegpunktbasierte Navigation*: Anhand von Wegpunkten soll einerseits die Route des UAVs geplant und andererseits einzelne Wegpunkte mit konkreten Wahrnehmungsaufgaben wie Personen- oder Fahrzeugerkennung verbunden werden.
- b) *Bruttoflugzeit ca. 15 min*: Zur Abbildung des Beispielszenarios wird eine Nettoflugzeit von ca. 10 min bei einer Nettonutzlast von 2 kg veranschlagt. Aufgrund von Schwankungen der Akkulaufzeit (Alter, Temperatur) und zur Optimierung von Einstellungen während des Fluges (Einschwingen des inertiales Navigationssystem, Anpassungen/Kalibrierung der Kameras, Überprüfung der Datenverbindungen) war



eine zeitliche Reserve vorgesehen, wodurch sich eine geforderte Bruttoflugzeit von 15 min ergab.

- c) *Fluggeschwindigkeiten von 0-40 km/h*: Neben der Fähigkeit zum Schwebeflug sind zur Abdeckung des Szenarios auf dem Testgelände Geschwindigkeiten von ca. 40 km/h ausreichend.
- d) *Flughöhe < 50 m*: Die maximale Flughöhe von ca. 50m ergab sich aus Sicherheitsaspekten, der Anfälligkeit für Vibrationen und Windböen sowie aus der limitierten Reichweite der verbauten Missionssensoren (u.a. LIDAR und feste Brennweite des LWIR-Sensors).
- e) *Reichweite < 1 km*: Sie resultiert aus Dimension und Lage des Testgeländes sowie aus der max. möglichen Reichweite der Funkverbindung zwischen Fluggerät und Sicherheitspiloten.
- f) *Einfache Handhabung*: Sowohl für die Erprobung im Rahmen dieser Arbeit als auch für das Beispielszenario war eine einfache Handhabung bei Start/Landung und während des Fluges gefordert.
- g) *Multisensor-Setup*: Zur Untersuchung eines optimierten Einsatz diversitärer Sensoren mussten unterschiedlichen Sensorarten und -konfigurationen integriert und deren Daten zeitlich- & örtlich synchronisiert aufgezeichnet und ausgewertet werden.
- h) *Nettonutzlast < 2 kg*: Um die Zulassungsanforderungen (Aufstiegsgenehmigung) und um eine einfache Handhabung zu gewährleisten, sollten kleine UAVs (Gesamtgewicht < 7 kg) eingesetzt werden. Daher war die Nettonutzlast auf ca. 2 kg beschränkt.

Auf Grundlage dieser Anforderungen entstanden im Rahmen dieser Arbeit das Fluggerät (Okto-XL, Abschnitt 8.3.1) und die Sensor-Rechner-Nutzlast (SOMA, Abschnitt 8.3.2).

### 8.3.1 Unbemanntes Fluggerät (Okto-XL)

Aufgrund der Forderung nach Schwebeflug, den Flugeigenschaften sowie der einfachen Handhabung wurde eine batteriebetriebene Schwebepattform als Ausgangskonfiguration ausgewählt. Dazu wurden achtmotorige Mikrokopter<sup>52</sup> UAVs der Firma HiSystems GmbH (*Okto-XL*, Abb. 50) ausgewählt und modifiziert. Im Vergleich zu Starrflügler-Fluggeräten ist hierbei ein Senkrechtstart/eine Senkrechtlandung ohne Landebahn möglich ist.

Bei der Auswahl des UAVs waren neben Preis und Verfügbarkeit die folgenden Funktionen des Mikrokopter Projektes<sup>53</sup> ausschlaggebend:

- *Komfort Funktionen / einfaches Handling*: Diese umfassen u.a. Autostart und Autoland, Coming-Home manuell oder beim Unterschreiten einer kritischen Batteriespannung, Dynamic Position-Hold zur Reduktion der Windanfälligkeit, Fluggrenzen/-käfig, Flugsimulator zum Training, Flugschreiber.

---

<sup>52</sup> <https://www.mikrokopter.de/de/produkte/kopter-oktoxl6s12>

<sup>53</sup> <https://www.mikrokopter.de/de/support/funktionen>


- *Redundanz*: Die Fluglageregelung erkennt den Ausfall eines Motors und regelt die verbleibenden Motoren sofort nach, so dass eine Notlandung möglich wäre.
- *RC-Datenlink*: Hierdurch sind Eingriffsmöglichkeiten für den Sicherheitspilot mit erhöhter Ausfallsicherheit gegeben.
- *Wegpunktnavigation*: Wegpunkte und Flugdaten lassen sich sowohl über die proprietäre Benutzerschnittstelle als auch über ein serielles Protokoll senden und empfangen.
- *Quelloffenes Projekt*: Anpassungsmöglichkeiten sind explizit möglich. Dies schließt strukturelle/mechanische Modifikationen und die Einstellbarkeit der Flugregelung ein.

Im Rahmen dieser Arbeit wurden u.a. die folgenden Modifikationen durchgeführt:

- *Tausch der Aktuatoren*: Durch den Einsatz von effizienteren bürstenlosen Motoren und größeren Propellern konnten sowohl die Flugleistung als auch die Schubkraft merklich gesteigert werden. Bei einer Nutzlast von bis zu 3 kg und einem Gesamtgewicht von ca. 7 kg konnte so in Erprobungsflügen (Abb. 50) eine Flugdauer von ca. 18 min erzielt werden.
- *Einsatzoptimierte Nutzlastaufnahme*: Diese umfasste die Verstärkung/Versteifung der Struktur (Ausleger) sowie die schwingungsgedämpfte, einsatzoptimierte Befestigung der Nutzlastaufnahme.
- *Hochkapazitive Energieversorgung*: Hierzu wurden Lithium-Polymer Akkumulatoren (LiPo, 14,8 VDC, 4x 6500 mAh, 2S2P Konfiguration) so platziert, dass der Gesamtschwerpunkt bei einer Nutzlast von ca. 2,5 kg etwa im Drehpunkt/Drehachse des Fluggeräts lag. Die Akkus dienen sowohl zum Betrieb des Fluggerätes und als auch zur Energieversorgung der Nutzlast (Rechner, Sensoren), woraus eine Gewichtersparnis im Vergleich zu einer dualen Spannungsversorgung resultierte.

Diese Änderungen ermöglichten die geforderte Flugleistung im Rahmen des Beispielszenarios (Abschnitt 8.3). Zur Abstimmung der Flugregler und zur Ermittlung der Flugleistung wurde eine Reihe Test-/Erprobungsflügen vor den eigentlichen Versuchen durchgeführt.


Zur Überwachung der Flugzustände und Umschalten zwischen einzelnen Wegpunkten wurde eine serielle Kommunikation zwischen Missionsrechner (Abschnitt 8.3.2) und Flugregler programmiert und eingesetzt.



**Abb. 50:** Fluggerät Okto-XL (Durchmesser ca. 1010 mm) in Vorversuchen zum Einstellen der Flugregler und zur Bestimmung der maximalen Nutzlast bei einer Flugzeit von ca. 18 min.

### 8.3.2 Sensor-Rechner Nutzlast (SOMA)

Die zur Erprobung des SPMS-Konzepts entworfene und eingesetzte Nutzlast SOMA (engl. *sensor oriented mission avionics*) besteht aus modularen Funktionsbaugruppen (Abb. 51) und umfasst die folgenden Hauptgruppenelemente.



**Abb. 51:** SOMA-Konstruktion: links) Multi-Missionsrechner Konfiguration mit 2 Einplatinenrechner, zentraler Lage von INS (orange) und Stromversorgung (rot), rechts) Multisensor-Konfiguration: 4-fach EO-Kamera-System mit unterschiedlichen Objektiven und Ausrichtungen, 1-Zeilen LIDAR und thermischer LWIR-Kamera.


- *Missionsrechner:* Die Missionsrechner dienen primär zur Sensordatenaufzeichnung und deren Verarbeitung. Sie könnten jedoch ebenfalls zur intelligenten Missionsplanung und zur Kompression/Übertragung von Sensordaten eingesetzt werden. Hierbei können je nach SOMA-Konfiguration bis zu 2 Einplatinenrechner im Standard Embedded Formfaktor 3,5“ verbaut werden (Abb. 51). In den Versuchsflügen wurde ein stromsparender Notebookchipsatz<sup>54</sup> (45 Watt) mit Intel i7 Quad-Core CPU, 8 GB Arbeitsspeicher und 512 GB SSD integriert und eingesetzt.
- *Multisensor-Konfiguration:* Hierbei wurden neben einem farbgebenden Mehrfachkamera-System, eine LWIR-Kamera zur thermischen Bildverarbeitung sowie Entfernungssensoren (LIDAR) zum Erstellen und Auswerten der Hindernis-/Höhengittern integriert. Zum Referenzieren/Akkumulieren von Sensordaten sowie zum Aufzeichnen genauer Positions- und Lagedaten kommt zudem ein im Dreh-/Sensormittelpunkt angebrachtes inertiales Navigationssystem (INS) zum Einsatz.
- *Breitbandige Datenverbindung:* Zur Flugversuchskontrolle/-überwachung sowie zum Einstellen und zur Echtzeitübertragung der Sensoren wurde neben dem sicherheitskritischen RC-Datenlink (Abschnitt 8.3.1) eine breitbandige Verbindung über WLAN gewählt. Hierzu wurden leistungsstarke, störungsunempfindliche mini-PCI WLAN-Router-Karten<sup>55</sup> und rundumstrahlende, empfangsverstärkende Antennen in SOMA integriert.
- *Flexibles Rahmenkonzept:* In der umgesetzten Lösung bietet SOMA einerseits größtmögliche Flexibilität hinsichtlich der Integration/Einbaulagen der Komponenten. Gleichzeitig resultiert aus der CFK-Rahmenkonstruktion eine Gewichtsreduktion, die dennoch die benötigte Steifigkeit und Vibrationsdämpfung gewährleistet.

<sup>54</sup> <http://www.comnell.com.tw/Product/SBC/LS-37B.HTM>

<sup>55</sup> [http://dl.ubnt.com/sr71a\\_datasheet.pdf](http://dl.ubnt.com/sr71a_datasheet.pdf)

Wie in Abb. 52 dargestellt, wird hierbei die Nutzlast unterhalb der Rotor-/Propellerebene montiert. So ergibt sich eine strikte Trennung zwischen Flugversuchsträger, RC-Funkstrecke und Energieversorgung einerseits (oben) sowie Sensornutzlast und Missions-/Sensordatenlink andererseits (unten). Hieraus ergeben die folgenden Vorteile:

- Gesteigerte Ausfallsicherheit: Defekte/Ausfälle in der Nutzlast haben nur einen geringen Einfluss auf die sicherheitskritische Flugregelung.
- Montage und Wartung werden vereinfacht.
- Getrennte Testmöglichkeiten von Fluggerät und Nutzlast vereinfachen die Entwicklung und die Inbetriebnahme.
- Skalierbarkeit und Erweiterbarkeit für andere Fluggeräte und neue Sensoren werden ermöglicht.



**Abb. 52:** Die Sensornutzlast SOMA wurde als modulares, vibrationsgedämpftes und leichtgewichtiges Nutzlastkonzept konzipiert: 1-2 Missionsrechnern (ECB), Mehrfachkamera (4x EO) mit unterschiedlichen Objektiven (rechts, Brennweiten), thermische LWIR-Kamera (IR), leichtgewichtiger Entfernungssensor (LIDAR), Positions-/Lagesensor (AHRs/INS) im Zentrum der Sensoren und in Nähe der Drehachsen des UAVs.

Das modulare, multisensorischen Nutzlastkonzept von SOMA ermöglicht die Wahl unterschiedlicher Sensor-Einbaulagen (breites, horizontales vs. verlängertes, vertikales Sichtfeld) und die Einsetzbarkeit bei dynamischen/erschweren Belichtungsverhältnissen (variablen Blende/Belichtungszeiten) durch situationsoptimale Kombinationen unterschiedlicher Sensorarten und Optiken. Zudem kann durch unterschiedliche Brennweiten der einzelnen Kameras eine vergrößerte Sensorabdeckung (kleine Brennweite, Weitwinkelobjektiv) und gleichzeitig eine erhöhte Bodenauflösung (große Brennweite, Zoomobjektiv in hohen Flughöhen) abgedeckt werden. Weiterhin können für die einzelnen Kameras unterschiedliche Blickrichtungen (Abb. 51) oder sensortypische, optimierte Voreinstellung fest eingestellt werden. Solche Einstellung werden üblicherweise für den Weißabgleich, den Kontrast oder die Belichtungszeit als Kompromiss aus Lichtempfindlichkeit und Framerate/Bewegungsunschärfe bei hohen Geschwindigkeiten nachjustiert.

Im Zuge des SPMS-Konzeptes sollen die Eigenschaften von SOMA einerseits während der Kettenmodellierung abgebildet (Abschnitt 6.6) und beim Einsatz während des Fluges gewinnbringend ausgenutzt werden.

## 8.4 Kettenimplementierung

Die grundlegenden Architekturen und Methoden der Bild- und Sensordatenverarbeitung wurden in ausführlich Abschnitt 3.2 beschrieben. Dieser Abschnitt befasst sich daher nur mit der Auswahl einer geeigneten Kettenarchitektur hinsichtlich einer Integration auf kleinen UAS sowie dem Training der implementierten Ketten.

### 8.4.1 Auswahl der Architektur

Die Auswahl einer geeigneten Kettenarchitektur erfolgte gemäß der Zusammenfassung in Abschnitt 3.2.4:

- Vision Transformer Ansätze versprechen zwar eine hohe Kettenleistung, benötigen jedoch eine enorme Rechenleistung und umfangreiche Trainingsdaten.
- CNNs, stellen dagegen einen guten Kompromiss dar, da sie sowohl zuverlässig (gute Kettenleistung) als auch auf mobilen Plattformen einsetzbar sind.

CNN-basierte Objekterkennungsmethoden können dabei in zweistufige (regionenbasierte) und einstufige Ansätze (Single-Shot-Detektoren, SSD) unterteilt werden. Regionenbasierte Modelle haben eine etwas höhere Genauigkeit, während SSDs effizienter sind (höhere Geschwindigkeit und geringerer Speicherbedarf) und dennoch eine gute Genauigkeit aufweisen. SSDs sind derzeit die beste Wahl für den Einsatz auf kleinen UAVs [LWZF20].

Aufgrund der frei verfügbaren und sehr effizienten C++-Implementierung fiel die Entscheidung zugunsten von YOLOv4, welches im nächsten Abschnitt detaillierter erläutert wird.

### 8.4.2 Varianten für kleine Fluggeräte

YOLOv4 (You Only Look Once version 4) ist ein Standardobjekterkennungsnetzwerk [BoWL20, WaBL22]. Es bildet die Grundlage für andere Varianten (YOLOv4-CSP, YOLOv4-Px, YOLOv4-tiny), die sich in Bezug auf die Architektur, Größe und Leistung unterscheiden:

- YOLOv4-CSP steht für YOLOv4 mit CSP (Cross-Stage-Partial) verbesserter Architektur. Es handelt sich um eine aktualisierte Architektur von YOLOv4, die eine verbesserte Genauigkeit und Geschwindigkeit bietet. CSP verbessert den Informationsfluss zwischen den verschiedenen Schichten des Netzwerks und sorgt so für eine bessere Abstraktionsfähigkeit bei der Erkennung von Objekten.
- YOLOv4-P5 bis P7 sind die „high-performance“ Versionen von YOLOv4. Sie besitzen zusätzliche Eingangsschichten und können daher größere Eingangsbilder mit höherer Detailierung verarbeiten. Sie erzielen gerade bei schwierigen Objekten und komplexen Szenen eine höhere Genauigkeit, allerdings auf Kosten der Rechenzeit bzw. mit einem deutlich gestiegenen Ressourcenverbrauch.
- YOLOv4-tiny stellt eine vereinfachte Variante von YOLOv4 dar, die über weniger Parameter und Schichten verfügt. Dies führt zu einer höheren Geschwindigkeit und einem geringeren Ressourcenbedarf, jedoch auf Kosten der Genauigkeit. Daher eignet sich YOLOv4-tiny besonders für Anwendungen mit begrenzten Ressourcen, beispielsweise auf eingebetteten Systemen oder kleinen UAVs.

**Tabelle 3:** Vergleich aktueller YOLOv4-basierten Objektdetektoren gemäß [WaBL21] und evaluiert auf COCO [LMBH14] mit einer NVIDIA RTX 2070 GPU.

Model	HW-Plattform	Input Size	AP <sub>50</sub>	FPS
YOLOv4-CSP	Workstation GPUs	640x640	66.2 %	73
YOLOv4-P5	High-End GPUs	896x896	70.3 %	41
YOLOv4-P7	Server / Cloud GPUs	1536x1536	73.4 %	16
YOLOv4-tiny	Embedded GPUs (NVIDIA Jetson)	416x416	40.2 %	330

Insgesamt bieten diese drei Varianten von YOLOv4 unterschiedliche Vor- und Nachteile in Bezug auf Leistung, Genauigkeit und Ressourcenverbrauch. Die Wahl des geeigneten Modells hängt von den spezifischen Anforderungen und Einschränkungen des Anwendungsfalls ab. Zur Verdeutlichung sind Parameter und Ergebnisse der Modelle auf bodengestützten Referenzdaten (COCO, [LMBH14]) gemäß [WaBL21] in Tabelle 3 zusammengefasst.

Die Integration von High-End- oder Server-GPUs in kleine oder mittlere UAVs erscheint auch auf mittlere Sicht nicht realistisch. Aus diesem Grund wurden zur Evaluierung lediglich YOLOv4-CSP und YOLOv4-tiny Modelle trainiert und eingesetzt.

### 8.4.3 Kettensetup und Training

Das Ketten-Setup für die Evaluierung des SPMS-Konzepts sollte einerseits generische EO- und IR-Ketten und andererseits spezialisierte Ketten umfassen, die für bestimmte Umweltparameter optimiert sind.

Die **generischen Ketten** wurden anhand von Trainingsdaten mit hoher Variabilität trainiert. Sie sollen universal und flexibel einsetzbar sein und nehmen im Rahmen des SPMS-Konzeptes die Rolle von Fallback-Ketten ein, falls keine spezialisierten Ketten gefunden werden.

Die **spezialisierten Ketten** wurden dagegen explizit anhand von gefilterten Trainingsdatensets auf erschwerte Umweltbedingungen ausgelegt, unter denen generische Ketten Schwächen aufweisen. Das eingesetzte Versuchssetup umfasst die folgenden spezialisierten Ketten:

- EO-Ketten für erschwerte Restlicht-Bedingungen (EO-Dämmerung: Restlicht)
- EO-Ketten für dedizierte Unter- bzw. Hintergründe (EO-Schnee: Schneebedeckung)
- IR-Ketten für inhomogene Temperaturen (IR-Gras: für erschwerte Bedingungen bei Flügen an heißen Tagen über Vegetation).
- IR-Ketten für homogene Temperaturen des Untergrundes (IR-Kalt: winterliche, kalte Bedingungen)

Für alle obigen Varianten wurden jeweils YOLOv4-CSP und YOLOv4-tiny Modelle trainiert und entsprechende Ketten implementiert. Hierdurch entsteht ein großer, repräsentativer Lösungsraum alternativer Ketten (vgl. Perception-Module-Graph in Abb. 27), der nicht nur zur Bearbeitung von Wahrnehmungsaufträgen (MMS) genutzt werden kann, sondern auch zur Evaluierung der Multikriterien-Rangfolgeerstellung (Abschnitt 7.2).



Die Grundlage der Ketten-Implementierungen bildet ein effizientes C++ Framework (Darknet, [BoWL20]), wodurch sich eine nahtlose Integration in das bestehende SPMS-Framework realisieren ließ.

Für das **Training** und die **Validierung** wurden insgesamt 33 000 EO-Bilder und 8 500 IR-Bilder mit *Personen* und *Fahrzeugen* annotiert, ausgewertet und in unterschiedliche Trainings- und Testdatensets sortiert.

Das Training der CNNs wurde auf einer NVIDIA DGX-Workstation mit einem Verbund von vier speziellen Grafikkarten (A100) durchgeführt. Die CNNs wurden auf dem COCO-Datensatz mit zwei Klassen (Personen und Autos) vortrainiert. Anschließend wurden diese vortrainierten Netze durch Transferlernen mit eigenen Trainingsätzen spezialisiert, die aus den Trainingsflügen (Tabelle 5) stammen.

Um die CNNs robust gegenüber realen Flugbedingungen zu machen, wurden einerseits Datenaugmentationstechniken [LNSH23] und andererseits die Fähigkeiten der Multisensor-Payload (SOMA, Abb. 51) genutzt. Hierdurch konnten Trainingssets mit hoher Variabilität und Spezifität erstellt werden. Neben jahres- und tageszeitabhängigen Variationen der Umweltzustände, der Szenerie und des Unter- bzw. Hintergrundänderung beinhalten die Datensets u.a. unterschiedliche Rotationen, Spiegelungen, Scherungen, Bilder mit unterschiedlichen Farb- und Helligkeitsverläufen sowie verschiedene Auflösungen und Perspektiven.

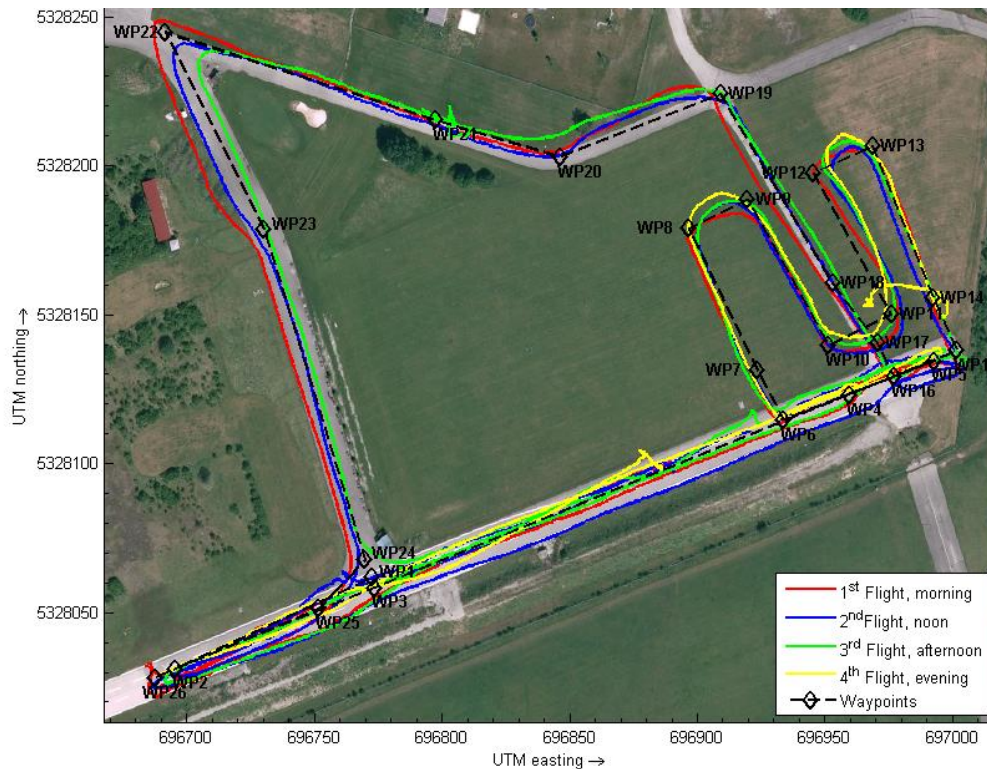
## 8.5 Versuchsdurchführung

Das Anwendungsszenario – Einsatz eines kleinen UAS zur Unterstützung von Rettungskräften nach Abb. 49 – wurde so skaliert, dass die Erprobung auf Testfluggelände der Universität der Bundeswehr in Neubiberg durchgeführt werden konnte (Abb. 53).



**Abb. 53:** Einsatz und Erprobung eines kleinen UAS zur möglichen Unterstützung von Rettungskräften bei Unfallszenarien auf dem Testgelände der Universität der Bundeswehr in Neubiberg.

Die Flugroute des UAV wurde anhand von Wegpunkten geplant. Einzelne Wegpunkte wurden mit konkreten Wahrnehmungsaufgaben wie der Erkennung von Personen oder Fahrzeugen verknüpft. Die Flugmuster bestanden aus einer Kombination von niedrigen, geraden Überflügen und mäanderförmigen Suchmustern.



**Abb. 54:** Wegpunkte und Flugkurven der ersten Sommerflugkampagne.

Zwischen Frühjahr 2013 und Winter 2021 fanden insgesamt ca. 40 Flugversuche statt. Flugrouten, Datum und Uhrzeit der Flugversuche sind in der folgenden Tabelle zusammengefasst.

Die Gesamtheit aller Flugversuche lässt sich in die drei folgenden Kategorien unterteilen:

- a) Erprobung des UAVs (Okto-XL, Abb. 50) und der Payload (SOMA, Abb. 52)
- b) Trainingsdaten-Gewinnung (u.a. 2014-07-04)
- c) Evaluierungsflüge zur Testdaten-Aufzeichnung im Rahmen des Anwendungsszenarios

Die Erprobungsflüge während der ersten Testphase (a: 2012-2013) wurden zur Abstimmung des Flugreglers, Integration und Konfiguration der Sensoren, Ermittlung der Flugleistung und Anpassung der Wegpunkte sowie zum Test der Software<sup>56</sup> benötigt.

Zum Training generischer und an einen Kontext adaptierter Ketten (Abschnitt 8.4.3) wurden Sensordaten hoher Variabilität und Spezifität benötigt. Die verschiedenen Trainingsdatenbanken wurden aus aufgezeichneten Sensordaten der Trainingsphase (b) erstellt. Hierfür wurden einzelnen Aufnahmen annotiert, augmentiert, geprüft und gefiltert.

Zur Evaluierung des SPMS-Konzeptes (Abschnitt 8.1.2) wurden zusätzliche Testflüge (c) zu verschiedenen Jahres- und Tageszeiten und bei unterschiedlichen Wetter- und Temperaturbedingungen durchgeführt. Zur besseren Einhaltung des Versuchsablaufs und Kontrolle der Szenerie (Personen und Fahrzeuge) wurde dabei das Szenario auf seine

<sup>56</sup> U.a. Interprozesskommunikation und Aufzeichnung zeitlich-örtlich synchronisierter Datensätze



Kernelemente (WP6-WP19 in Abb. 54) beschränkt. Die Flugrouten und eine Aufstellung der Umweltbedingungen der Evaluierungsflüge sind in Abb. 55 und Tabelle 4 wiedergeben. Die Bilder und Ergebnisse im Auswertekapitel 9 stammen ebenfalls aus diesen Flügen.

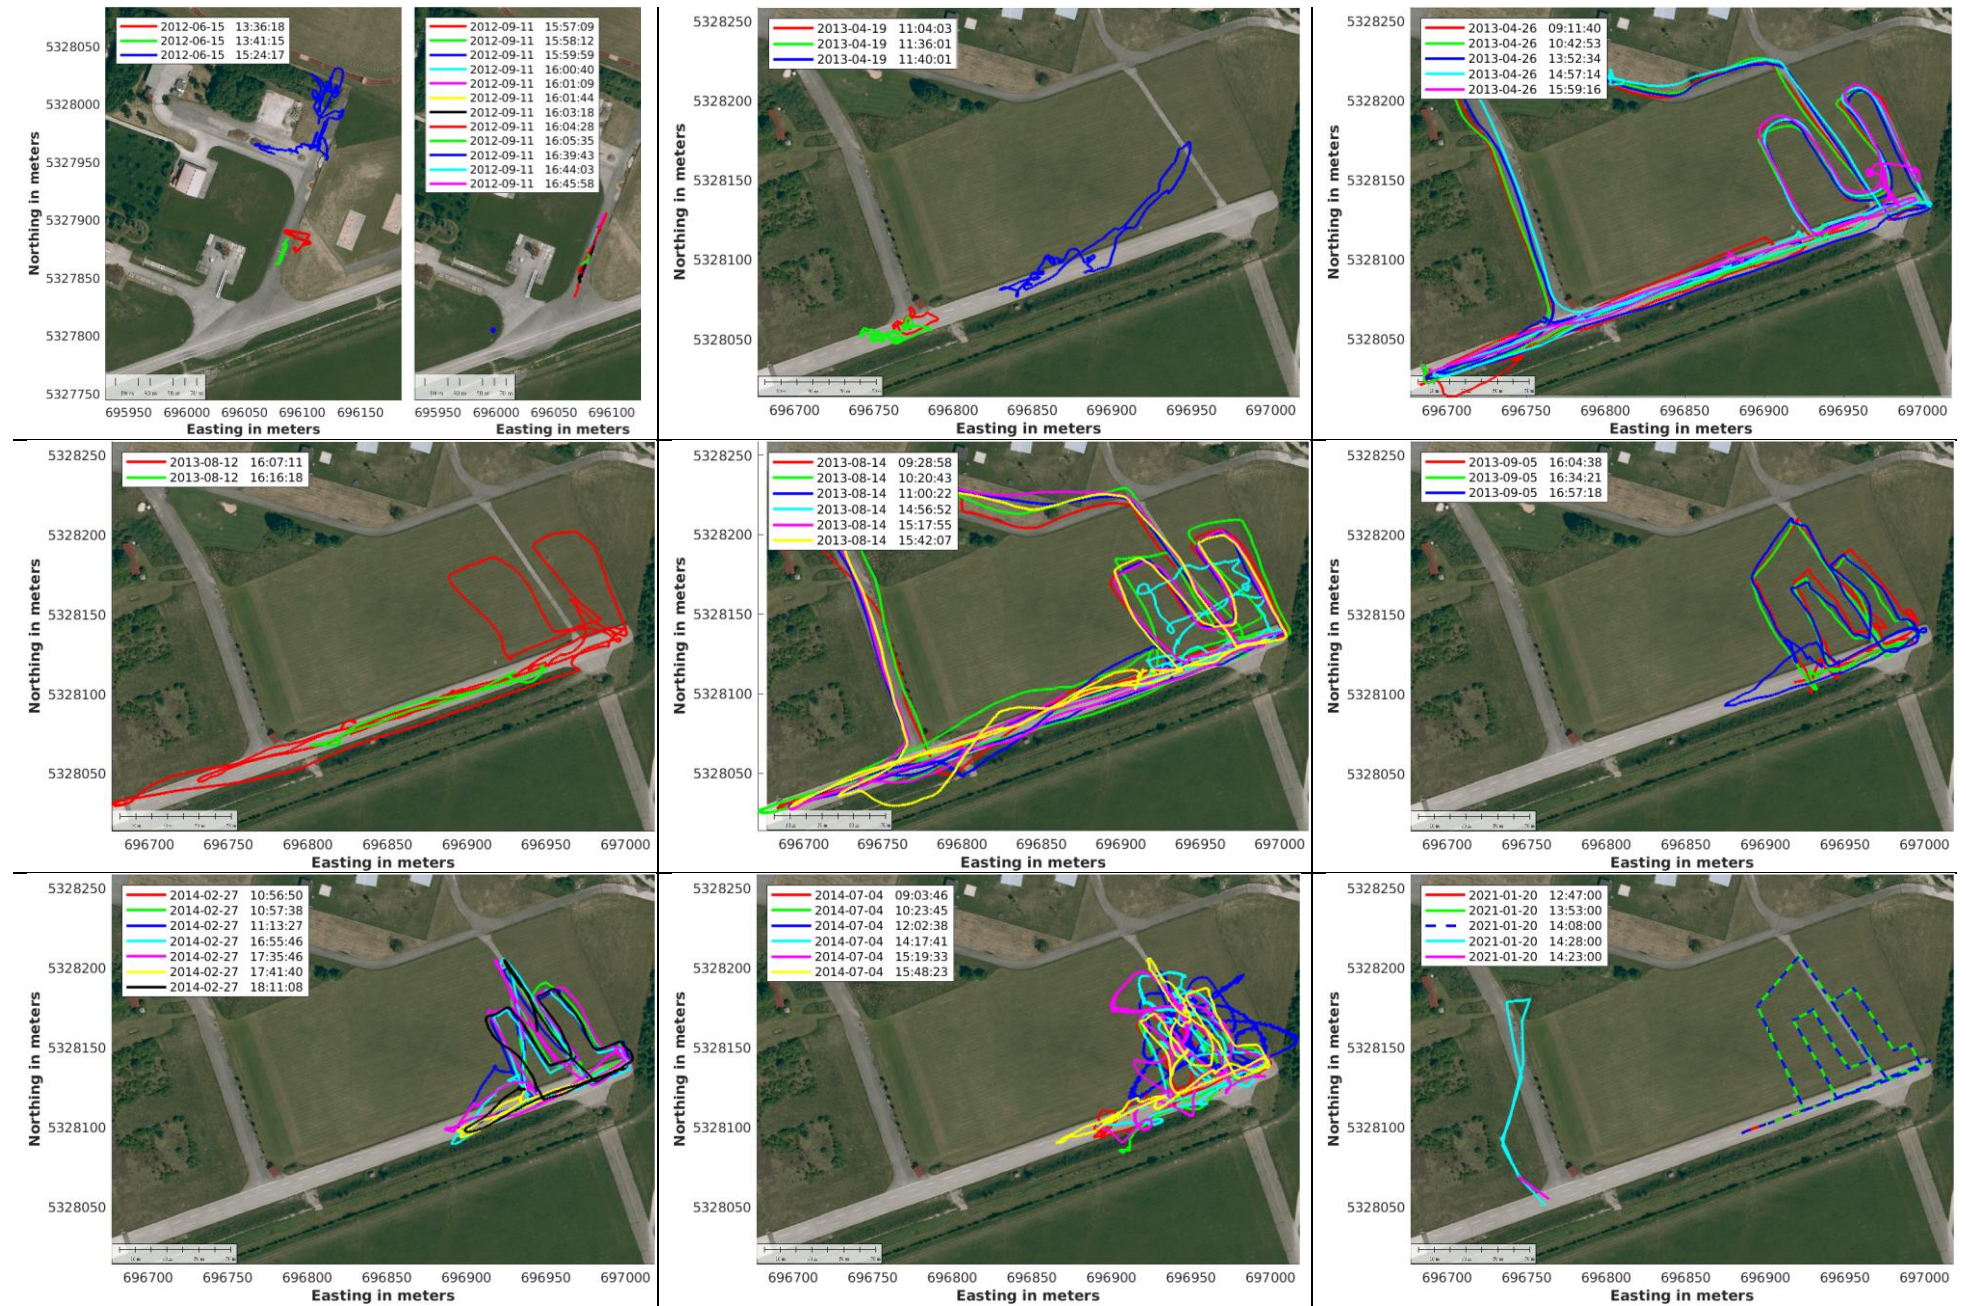


**Abb. 55:** Für die Bewertung verwendete Flugbahnen, Daten und Tageszeiten.

**Tabelle 4:** Ausgewählte Flugversuche, die zur Evaluierung der Untersuchungsgegenstände selektiert wurden

<i>Datum</i>	<i>Uhrzeit</i>	<i>Jahreszeit</i>	<i>Licht</i>	<i>Wetter</i>	<i>Temp. °C</i>	<i>Untergrund</i>	<i>Flughöhe</i>	
<b>2013-09-05</b>	06:38:00	Herbst	warm	sonnig	14°	grün/braun	15m	
	<b>16:57:18</b>		lange Schatten		24°		warm/heiß	30m
	19:45:00				28°			55m
<b>2014-02-27</b>	06:59:00	Spät-Winter	kalt	bewölkt	-1°	kalt	18m	
	<b>11:13:27</b>		kaum Schatten		3°			
	17:52:00				7°			
	06:59:00	Spät-Winter	Dämmerung	bewölkt	-1°	kalt	18m	
	<b>17:35:46</b>		nach		4°			
	17:52:00		Sonnengang		7°			
	06:59:00	Spät-Winter	Restlicht, finster	bewölkt	-1°	kalt	18m	
	<b>18:11:08</b>		nach		4°			
	17:52:00		Sonnengang		7°			
<b>2014-07-04</b>	05:20:00	Sommer	Morgengrau,	sonnig	16°	heiß	18m	
	<b>09:03:46</b>		rötlich-warm		22°			
	21:15:00		Schatten		31			
	05:20:00	Sommer	hart,	sonnig	16°	heiß	18m	
	<b>15:48:23</b>		überbelichtet		26°			
	21:15:00		Schatten		31°			
<b>2021-01-20</b>	07:55:00	Winter	neutral	sonnig	-3°	weiß	50m	
	<b>14:08:00</b>		kurze Schatten		3°			(Schnee)
	16:54:00				7°			kalt

Tabelle 5: Flugversuche zur Generierung von Trainings- und Testdaten



## 9. Auswertung und Ergebnisbewertung

Zur Bewertung des SPMS-Konzeptes (Kapitel 5) und der gewählten Methoden (Abschnitte 6.6, 7.1, 7.2) wurde ein mehrstufiges Evaluierungskonzept (Abschnitt 8.1) entworfen, mit dem eine Beantwortung der Forschungsfragen und eine Validierung der systematischen Anforderungen (Abschnitte 4.1, 4.2) ermöglicht werden soll.

Die einzelnen Untersuchungsgegenstände spiegeln sich daher in der Struktur dieses Kapitels wider, wobei zusätzlich ein erläuternder Abschnitt zum verwendeten Auswerteschema, der Leistungsmetrik sowie der Nomenklatur vorangestellt ist.

### 9.1 Schema der Versuchsauswertung

Die zur Auswertung und Evaluierung der Untersuchungsgegenstände notwendigen Versuche fanden anhand realer Flugkampagnen (Abschnitt 8.5) statt. Hierfür wurde ein Flugversuchsträger (Okto-XL, Abschnitt 8.3.1) und eine multi-sensorische Sensor-Rechner-Nutzlast (SOMA, Abschnitt 8.3.2) konstruiert, aufgebaut und während der Flugversuche eingesetzt. Die alternativen Kettenimplementierungen und deren Training sind in Abschnitt 8.4 näher beschrieben.

Eine Überprüfung der systematischen Anforderungen und der Test von Teilfunktionalitäten wie das Kettenmanagement, die Rangfolgeerstellung oder das Fähigkeitenprinzip wurden bereits vorab während der Entwicklungsphase (Abschnitt 7.3) untersucht.

Zur Leistungsbestimmung der Ketten wird auf die gängige<sup>57</sup> Bestimmung der durchschnittlichen Präzision (*Average Precision*, AP) für jede Objektklasse anhand der *Precision-Recall Kurve* (PRK) zurückgegriffen. Die PRK (Abb. 56) zeigt den Zusammenhang zwischen *Precision* (Genauigkeit) und *Recall* (Sensitivität) bei verschiedenen Schwellwerten für die Klassifikationsentscheidung. Die beiden Hauptkomponenten der Precision-Recall-Kurve sind:

- *Precision* ist das Verhältnis der korrekt positiv klassifizierten Instanzen (*True Positives*, TP) zur Summe der korrekt positiv klassifizierten Instanzen und der falsch positiv klassifizierten Instanzen (*False Positives*, FP). Sie gibt die *Genauigkeit* an, mit der ein Modell richtige Vorhersagen im Sinne einer positiven Entscheidung trifft:

$$Precision = \frac{TP}{TP + FP} \quad (\text{F. 11})$$

- *Recall*, auch als *Sensitivität* oder *True Positive Rate* (TPR) bekannt, ist das Verhältnis der korrekt positiv klassifizierten Instanzen (TP) zur Summe der korrekt positiv

---

<sup>57</sup> PR-Metriken wurden bereits bei der PASCAL VOC Challenge [EGWW10] und bei der COCO Challenge [LMBH14] eingesetzt. Die PR-Metrik ist insbesondere bei unausgeglichenen Klassen oder bei unterschiedlichen Kosten für Fehlklassifikationen (False Positives und False Negatives) vorteilhaft gegenüber anderen Metriken wie ROC (Receiver Operating Characteristics) [SaRe15].



klassifizierten Instanzen und der falsch negativ klassifizierten Instanzen (FN). Der Recall gibt an, wie gut das Modell alle positiven Fälle erkennt:

$$\text{Recall} = \frac{TP}{TP + FN} \quad (\text{F. 12})$$

- *True Positives (TP)* sind Fälle, bei denen das Modell korrekt einen positiven Fall als positiv klassifiziert. Sie sind für die Berechnung sowohl der Precision als auch des Recall wichtig, da sie die Anzahl der korrekten positiven Vorhersagen darstellen. Je mehr True Positives ein Modell hat, desto höher sind Precision und Recall.
- *False Positives (FP)* sind Fälle, bei denen das Modell eine positive Klassifikation vorhersagt, obwohl die tatsächliche Klasse negativ ist. Ein hoher Anteil an FPs führt zu einer niedrigeren Precision, da das Modell viele falsche positive Vorhersagen trifft. In diesem Zusammenhang ist es wichtig, eine geeignete Balance zwischen Precision und Recall zu finden, um das Modell für die gegebene Anwendung optimal zu gestalten.
- *False Negatives (FN)* sind Fälle, bei denen das Modell fälschlicherweise eine positive Instanz als negativ klassifiziert. Sie sind besonders problematisch in Situationen, in denen das Nichterkennen einer positiven Instanz schwerwiegende Konsequenzen hat.

Die PRK wird erstellt, indem Precision und Recall bei verschiedenen Schwellwerten für eine Klassifikationsentscheidung berechnet und gegeneinander aufgetragen werden. Die resultierende Kurve zeigt, wie sich die Leistung des Modells in Bezug auf Precision und Recall bei verschiedenen Schwellwerten ändert. Je näher die Kurve an der oberen rechten Ecke des Koordinatensystems liegt, desto besser ist die Leistung eines Modells. Die perfekte Klassifikation würde in einer Kurve resultieren, die entlang der Y-Achse verläuft und dann entlang der X-Achse, wobei sowohl Precision als auch Recall den Wert 1.0 (100 %) erreichen. In der Praxis sind Kompromisse bei der Wahl des Schwellwerts zu treffen, da eine Verbesserung der Precision oft Verschlechterungen des Recalls nach sich zieht (und umgekehrt).

Für die Bewertung der Detektionsergebnisse wurde die Leistungsmetrik der Pascal VOC Challenge [EGWW10] wie folgt eingesetzt:

- Die Fläche unter der *Precision-Recall Kurve (PRK)* bei einer bestimmten *Intersection over Union (IoU)* ist die *Average Precision (AP)* pro Klasse.
- IoU beschreibt das Überschneidungsverhältnis zwischen Erkennungs- und Ground-Truth-Boxen. IoU wurde für kleine Objekte (Personen) auf 0,4 und für größere Objekte (Autos) auf 0,6 festgelegt. Sie dient zur Bestimmung der TP, FP sowie der FN.

Um die Vergleichbarkeit und Reproduzierbarkeit der Flugversuche zu gewährleisten sollten mögliche Einflussfaktoren separiert betrachtet werden. Sowohl variierende Perspektiven als auch unterschiedliche GSDs (Bodenauflösung durch Flughöhe) haben einen sehr großen Einfluss auf die Leistung von Ketten. Sie hätten daher eine präzise Analyse der Umwelt- und Umgebungseinflüsse erschwert und wurden daher bei deren Untersuchung konstant gehalten.

Die Ergebnisse der Personendetektion sind in Tabellen zusammengefasst. Pro Evaluierungsflug (Abb. 55) werden neben der AP als weitere Metriken der F1, F2 und der F0.5 Score sowie die Zahl der Labels (GT), TP, FP, FN und die daraus ableitbare Precision und der Recall angegeben.

Um eine durchgängige, ganzjährige Einsatztauglich („24/7“) sowie Allwetterfähigkeit der Ketten und SPMS-System zu untersuchen, wurden zudem die einzelnen Referenzversuche zu einem über alle Flugversuche harmonisch verteilten Datenset (*All-Dates [2013-2021]*) zusammengefügt. Hierbei wurde das folgende Bewertungsschema zur Klassifizierung der Kettenleistung eingesetzt, das zudem in den folgenden Tabellen farblich hervorgegeben wird:

- **unzureichend** (rot): *Leistungsmetrik*  $\in [0,0 ; 0,4[$
- **kritisch** (orange): *Leistungsmetrik*  $\in [0,4 ; 0,7[$  → **Corner-Case**
- **ausreichend** (grau): *Leistungsmetrik*  $\in [0,7 ; 0,8[$  → **Edge-Case**
- gut (hell-grün): *Leistungsmetrik*  $\in [0,8 ; 0,9[$
- **sehr gut** (grün): *Leistungsmetrik*  $\in [0,9 ; 1,0[$  → **Einsatztauglichkeit**

Für Analysen der Kettenleistung hinsichtlich einer möglichen Abhängigkeit vom Hinter- bzw. Untergrund bieten sich die Wegpunkte der Flugversuche als Referenzpunkte an. Um eine auswerte- und aussagefähige Anzahl von Annotationen und Detektionen für jeden Wegpunkt und für jeden Flugversuch zu gewinnen, wurde jedem Wegpunkt ein Beobachtungszeitbereich zugeordnet ( $\text{Zeitspanne}_{wp} = t_{wp} \pm 25 \text{ Sekunden}$ ). Für jeden dieser Bereiche wurden obige Metriken (AP, F1, F2, F0.5) berechnet und über den Flugplan aufgetragen. Die Wegpunkte WP1-WP7 liegen auf der Straße und WP8-WP16 auf der Wiese des Testgeländes.

In den Test-Bildern sind alle beschrifteten Ground-Truth-Boxen (Personen und Fahrzeuge) grün während durch Ketten erkannte Personen rot und erkannte Fahrzeuge blau umrahmt sind.

## 9.2 Untersuchungen zur Anpassungsmöglichkeit von Ketten

Eine der Grundannahmen des SPMS-Konzeptes ist die situations- und umweltoptimale Anpassungsmöglichkeit vorkonfigurierter Sensoren und Algorithmen (Ketten). Das Setup zur Bewertung des SPMS-Konzeptes beinhaltet daher sowohl allgemeine, generische EO- und IR-Ketten als auch spezialisierte Ketten, die für bestimmte Umweltbedingungen oder für eine Implementierung auf Hardware mit eingeschränkten Ressourcen optimiert sind.

Detektionen und Ergebnisse der Ketten werden aufgezeigt und im Kontext des SPMS-Konzeptes analysiert. Zudem werden die tatsächlichen Detektions-Ergebnisse mit den durch Auswertung der Modelle vorhergesagten Kettenleistungen verglichen.

### 9.2.1 Generische und effiziente Ketten

Generische Ketten sollen im Rahmen des SPMS-Konzeptes die Rolle von Rückfall-Ketten einnehmen, falls spezialisierten Ketten zu schlecht bewertet oder nicht vorhanden sind. Folglich sollen sie universal und flexibel einsetzbar sein, um den normalen, erwarteten Betrieb abzudecken. Anhand ihrer Ergebnisse sollen zudem Rückschlüsse auf Edge-/Corner Cases abgeleitet werden. So bilden sie zugleich den Ausgangspunkt für die gezielte Spezialisierung von Ketten.

Die generischen Ketten wurden anhand von Trainingsdaten mit hoher Variabilität trainiert:

- Einerseits sollen generische Trainingsdaten dabei unterschiedliche Jahres- und Tageszeiten, variierenden Unter- und Hintergründen und unterschiedlichen Szenerien<sup>58</sup> abdecken.
- Andererseits soll die Zusammensetzung des generischen Trainingsdatensets den regulären, operationellen Arbeitsbereich betonen ohne Edge- und Corner-Cases überzubewerten.

Diese Überlegungen wurden bereits während der Planung der Flugversuche (Abschnitt 8.5) berücksichtigt. Aus über 40 Flugversuchen (Tabelle 5) wurden zunächst die späteren Evaluierungsflüge (Abb. 55) abgezogen. Die verbleibenden Datensätze wurden anschließend sortiert, gewichtet und von sehr speziellen Corner-Cases bereinigt, um eine dem nominalen Einsatzraum entsprechende Verteilung gut abzubilden<sup>59</sup>

Exemplarische Detektionsergebnisse der so trainierten generischen CNNs sind jeweils rechts in Abb. 56 und Abb. 57 dargestellt. Die entsprechenden PRKs und die resultierende AP sind jeweils links aufgeführt. Markante Ergebnisse der generischen Ketten sind zudem in Tabelle 6 farblich hervorgehoben und werden im Folgenden analysiert:

- Im nominalen Betrieb ist eine gute bis sehr gute Kettenleistung (AP, F-Scores) ersichtlich. Teilweise waren die Detektions-Ergebnisse so gut, dass Fehler bei der Annotation aufgedeckt wurden: Wie in Abb. 56 gezeigt, wurden Personen im Schatten richtig erkannt, aber vom Menschen übersehen (5 Personen im IR-Bild in Abb. 57).
- Im Vergleich zur Referenz-YOLOv4-Implementierung mit dem COCO-Datensatz (Tabelle 3) ist gerade bei den effizienten CNNs (ch-\*-tiny) die Leistung deutlich besser. Dies ist unter anderem darauf zurückzuführen, dass in den Versuchen nur zwei Klassen (Personen und PKWs, COCO: 80 Klassen) gelernt und unterschieden wurden. Um die Vergleichbarkeit und Reproduzierbarkeit der Flugversuche zu gewährleisten, wurden zudem mögliche Einflussfaktoren separiert betrachtet. Sowohl variierende Perspektiven als auch unterschiedliche GSDs (Flughöhe) hätten die Ergebnisse beeinträchtigt und wurden daher möglichst konstant gehalten.
- Im Ganzjahres-Datensatz (*All-Dates [2013-2021]*) weisen generische Ketten eine gute Leistung auf. Sie können also tatsächlich die Rolle von Rückfall-Ketten übernehmen.
- Unter bestimmten Umweltkonstellationen zeigen jedoch sowohl generische EO- als auch generische IR-Ketten auch Schwächen:
  - EO-Ketten:
    - Die Leistung der EO-Ketten ist bei Dämmerung (2014-02-27 [17:35:46]) eingeschränkt und bei Restlicht unzureichend (2014-02-27 [18:11:08]).
    - Ihre Leistung könnte bei schwierigen Konstellationen zwischen Vorder- und Hintergrund, beispielsweise bei künstlicher oder natürlicher Tarnung (Schnee-Datensatz 2021), möglicherweise noch durch Spezialisierung gezielt verbessert werden.
  - IR-Ketten:

<sup>58</sup> Variationen des Vordergrunds umfassen Posen & Kleidung von Personen sowie Fahrzeugtypen und -farben.

<sup>59</sup> Beispielsweise wurden für generische EO-Sets Flüge in der späten Dämmerung und Nacht herausgefiltert.

- Bei einer homogenen Temperatur-Verteilung des Untergrundes kann mit IR-Ketten eine sehr gute Erkennungsleistung erzielt werden, u.a. an kalten Tagen und/oder in der Nacht (bis in den Morgen).
- An heißeren Tagen und/oder bei direkter Sonneneinstrahlung zeigen IR-Ketten nur eine ausreichende und teilweise eine kritische Kettenleistung. Wie in den Detektionen unten links in Abb. 57 ersichtlich, können einerseits auf asphaltierten Flächen weiterhin gute Ergebnisse erzielt werden. Andererseits waren die Detektionsergebnisse über Vegetation mangelhaft. Hier sind die Untergrundtemperaturen stark „verrauscht“ und kleine Objekte nicht oder schwer vom Hintergrund segmentierbar<sup>60</sup>.
- Flugversuche mit ausreichender oder kritischer Leistung stellen die *Edge/Corner-Cases* dar, für die spezialisierte Ketten trainiert wurden. Deren Ergebnisse werden in den nachfolgenden Abschnitten mit der Leistung generischer Ketten verglichen und analysiert.
- Effiziente Ketten (ch-\*-tiny) sind für EO-Farbkameras (3-Kanal: RGB) etwas schlechter zu bewerten als normalen Ketten. Die kleinere Netzarchitektur wirkt sich jedoch bei LWIR-Sensordaten (1-Kanal: Temperatur) weniger nachteilig aus.

## Modellbildung




Die analysierten, kausalen Abhängigkeiten der Kettenleistungen wurden zur Modellierung einer Einsatzcharakteristik der Ketten genutzt. Die entworfenen BNs und die eingesetzten CPTs sind im Anhang auszugsweise zu finden. Wie in Abb. 58 gezeigt, kann so durch Auswertung der Modelle eine präzise Vorhersage der Kettenleistung getroffen werden. Der Modellierungsfehler (Abb. 58 unten) ergibt sich aus der Differenz zwischen der tatsächlichen Kettenleistung (*durchgezogene* Linie) und der vorgesagten Kettenleistung (*gestrichelt* Line, P(BN)). Hierbei schwanken die Modellierungsfehler generischer Ketten zwischen den folgenden Grenzwerten:

- ]0,0 ; +0,32]: Das Kettenmodell *unterschätzt*, d.h. für die Kette wird eine geringere Leistungsfähigkeit vorhergesagt, als sie tatsächlich erreicht. Im Zuge des SPMS-Konzeptes könnte dies dazu führen, dass andere, real schlechter funktionierende Ketten bevorzugt werden.
- [-0,20 ; 0,0[: Das Kettenmodell *überschätzt*, d.h. der Kette wird ein höheres Leistungsniveau zugeschrieben, als sie tatsächlich erreichen kann. Somit würde Sie gegebenenfalls im Vergleich zu besser funktionierenden Ketten bevorzugt.

Modellierungsfehler können dazu führen, dass nicht die besten Ketten ausgewählt werden. Da aus dem Vergleich und der Bewertung unterschiedlicher Ketten eine Rangfolge der Ketten abgeleitet wird, müssen folglich die Modellierungsfehler der spezialisierten Ketten zusätzlich mitberücksichtigt werden. Hierfür werden im abschließenden Abschnitt 9.2.6 die Modellierungsfehler ganzheitlich betrachtet. Dies führt zu unterschiedlichen Stoßrichtungen für die Modellierung und zu einer Modellierungsempfehlung im Sinne des SPMS-Konzeptes.





---

<sup>60</sup> Auch bei der manuellen Annotation durch den Menschen waren Personen im Grass häufig nur aufgrund der Bewegung erkennbar und wurden trotz EO-Referenzbildern teilweise übersehen.





**Abb. 56:** Generische EO-Ketten (oben: YOLOv4-CSP, unten: YOLOv4-tiny): Precision-Recall-Kurven mit AP (links) und Detektionsbeispiele (rechts): 2013-09-05 (links-oben), 2014-02-27 [17:35:46] (rechts-oben), 2014-07-04 [15:48:23] (links-unten), 2021-01-20 (rechts-unten).





**Abb. 57:** Generische IR-Ketten (oben: YOLOv4-CSP, unten: YOLOv4-tiny): Precision-Recall-Kurven mit AP (links) und Detektionsbeispiele (rechts): 2013-09-05 (links-oben), 2014-02-27 [17:35:46] (rechts-oben), 2014-07-04 [15:48:23] (links-unten), 2021-01-20 (rechts-unten).



**Abb. 58:** Leistungsverläufe generischer Ketten während der Testflüge über Straße (WP1-WP7) und Wiese (WP8-WP16): Detektionsleistung (oben) und Modellierungsfehler (unten).


**Tabelle 6:** Ergebnisse für generische Ketten (Threshold = 0,5, IOU = 0,4, Class = Person) mit folgendem Bewertungsschema:

unzureichend = rot [0,0 ; 0,4[ ... kritisch = orange [0,4 ; 0,7[ ... ausreichend = grau [0,7 ; 0,8[ ... gut = hell-grün [0,8 ; 0,9[ ... sehr gut = dunkel-grün [0,9 ; 1.0]

<i>Chain</i>	<i>Date</i>	<i>AP</i>	<i>F1</i>	<i>F2</i>	<i>F0.5</i>	<i>GT</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>Prec.</i>	<i>Recall</i>
<i>ch_eo-generic</i>	2013-09-05 [16:57:18]	0,85	0,90	0,89	0,92	292	257	19	35	0,93	0,88
	2014-02-27 [11:13:27]	0,94	0,93	0,94	0,92	169	161	16	8	0,91	0,95
	2014-02-27 [17:35:46]	0,66	0,76	0,71	0,81	202	138	25	64	0,85	0,68
	2014-02-27 [18:11:08]	0,01	0,02	0,01	0,05	95	1	0	94	1,00	0,01
	2014-07-04 [09:03:46]	0,96	0,96	0,97	0,96	426	415	21	11	0,95	0,97
	2014-07-04 [15:48:23]	0,96	0,97	0,97	0,97	494	479	16	15	0,97	0,97
	2021-01-20 [14:08:00]	0,79	0,88	0,84	0,93	3352	2707	76	645	0,97	0,81
	<i>All-Dates [2013-2021]</i>	0,82	0,89	0,85	0,92	2785	2322	123	463	0,95	0,83
<i>ch_eo-generic-tiny</i>	2013-09-05 [16:57:18]	0,87	0,90	0,90	0,90	292	264	31	28	0,89	0,90
	2014-02-27 [11:13:27]	0,95	0,91	0,94	0,88	169	163	25	6	0,87	0,96
	2014-02-27 [17:35:46]	0,75	0,81	0,79	0,84	202	155	24	47	0,87	0,77
	2014-02-27 [18:11:08]	0,04	0,08	0,05	0,16	95	4	3	91	0,57	0,04
	2014-07-04 [09:03:46]	0,94	0,93	0,95	0,91	426	411	48	15	0,90	0,96
	2014-07-04 [15:48:23]	0,85	0,88	0,88	0,88	494	436	57	58	0,88	0,88
	2021-01-20 [14:08:00]	0,77	0,85	0,83	0,87	3352	2731	336	621	0,89	0,81
	<i>All-Dates [2013-2021]</i>	0,81	0,87	0,85	0,88	2785	2339	281	446	0,89	0,84
<i>ch_ir-generic</i>	2013-09-05 [16:57:18]	0,58	0,73	0,63	0,86	323	187	4	136	0,98	0,58
	2014-02-27 [11:13:27]	0,84	0,88	0,87	0,90	193	166	17	27	0,91	0,86
	2014-02-27 [17:35:46]	0,99	0,94	0,97	0,90	248	248	33	0	0,88	1,00
	2014-02-27 [18:11:08]	0,91	0,90	0,92	0,88	194	181	29	13	0,86	0,93
	2014-07-04 [09:03:46]	0,67	0,78	0,75	0,81	494	362	70	132	0,84	0,73
	2014-07-04 [15:48:23]	0,71	0,81	0,75	0,89	545	391	25	154	0,94	0,72
	2021-01-20 [14:08:00]	0,90	0,93	0,92	0,95	3887	3513	128	374	0,96	0,90
	<i>All-Dates [2013-2021]</i>	0,78	0,86	0,82	0,90	3260	2614	220	646	0,92	0,80
<i>ch_ir-generic-tiny</i>	2013-09-05 [16:57:18]	0,61	0,75	0,66	0,86	330	202	8	128	0,96	0,61
	2014-02-27 [11:13:27]	0,88	0,87	0,88	0,86	193	172	31	21	0,85	0,89
	2014-02-27 [17:35:46]	0,99	0,91	0,96	0,86	248	248	49	0	0,84	1,00
	2014-02-27 [18:11:08]	0,94	0,85	0,92	0,79	195	189	60	6	0,76	0,97
	2014-07-04 [09:03:46]	0,70	0,80	0,77	0,83	494	368	61	126	0,86	0,74
	2014-07-04 [15:48:23]	0,70	0,79	0,75	0,83	545	396	67	149	0,86	0,73
	2021-01-20 [14:08:00]	0,90	0,93	0,92	0,94	3887	3542	178	345	0,95	0,91
	<i>All-Dates [2013-2021]</i>	0,79	0,84	0,82	0,87	3266	2648	354	618	0,88	0,81

### 9.2.2 Spezialisierte EO-Ketten für schwierige Bedingungen (Corner-Case)

Ein möglicher Grenzfall einer Verschlechterung der EO-Sensorqualität tritt bei ungünstigen Lichtverhältnissen z.B. während der Abend- oder Morgendämmerung auf (Abb. 59). Dies hat die Analyse generischer Ketten im vorherigen Unterkapitel belegt. Wie in Abb. 56 ersichtlich, brach die Kettenleistung generischer EO-Ketten bei Flugversuchen im Februar kurz vor Sonnenuntergang (2014-02-27 [17:35:46]) und noch deutlicher nach Sonnenuntergang (2014-02-27 [18:11:08]) ein. Im Gegenzug hierzu liefern thermische LWIR-Sensoren gerade bei Restlicht und in der Nacht sehr gute Rohdaten mit denen hervorragende Detektionsergebnisse ( $> 0.9$ ) erzielt werden können (vgl. Abb. 58).



**Abb. 59:** Sensoraufnahmen während der Dämmerung (links vor, rechts nach Sonnenuntergang): oben jeweils die Originalbilder, mittig manuell aufgehellt, unten IR-Sensor-Bilder aus Referenz/Orientierung.

Leistungsfähige Infrarotsensoren sind deutlich teurer, größer und schwerer als EO-Sensoren und häufig zudem exportbeschränkt. Ein erweiterter Einsatzraum von EO-Sensoren hätte daher einen großen praktischen Nutzen. Die folgenden Erfahrungen und Zusammenhänge flossen in die Implementierung spezialisierter Dämmerungs-EO-Ketten (*ch-eo-night*) ein:

- Bei der Annotation der Flugversuche konnte auch bei fast völliger Dunkelheit der Bilder durch manuelles Einstellen von Helligkeit (Gain) und Kontrast ein häufig brauchbares Bild rekonstruiert werden. Trotz starken Rauschens und falscher bzw. fehlender Farbinformationen war die menschliche Wahrnehmung fähig, Objekte zu erraten (Abb. 10).
- Um den Prozess zu automatisieren, wurden die Trainingsdaten nach dunklen Szenen gefiltert. Diese Dämmerungsdatensätze dienten zur Spezialisierung vortrainierter CNNs mittels Transfer-Learning (Abschnitt 8.4):
  - Aufgrund der verfärbten und verblassten Farben war die erste Versuchsreihe einer farbbasierten Implementierung der EO-Nacht-Ketten nicht zufriedenstellend.
  - Im zweiten Experiment wurden der COCO-Datensatz und unsere eigenen „Restlicht“-Datensätze zunächst in Graustufenbilder umgewandelt, bevor das Training erfolgreich wiederholt wurde.

Die Detektionen und Ergebnisse der spezialisierten Dämmerungs-EO-Ketten (*ch-eo-night*) sind in Abb. 61 und Abb. 62 dargestellt sowie in Tabelle 7 zusammengefasst. Hieraus lassen sich die folgenden Schlussfolgerungen ableiten:

- Im Vergleich zu den generischen EO-Ketten wurde eine **Verbesserung** des F2-Scores
  - bei Dämmerung (2014-02-27 [17:35:46]) zwischen: **10% bis 21%** (YOLOv4-CSP) bzw. **5% bis 18%** (YOLOv4-tiny) und
  - bei Restlicht (2014-02-27 [18:11:08]) zwischen: **34% bis 66%** (YOLOv4-CSP) bzw. **57% bis 61%** (YOLOv4-tiny) erzielt.
- Größere Netze liefern bessere Ergebnisse bei Dämmerung (Edge-Case), wohingegen eine kleine Netz-Architektur eine stärkere Spezialisierung an den Corner-Case (hier gewünschte Adaptierung für Restlicht) ermöglicht.
- Die Leistung der EO-„Nachtexperten“ ist der Detektionsleistung von IR-Ketten in der Dämmerung nur geringfügig unterlegen und nach Sonnenuntergang noch akzeptabel.
- Gerade bei Restlicht waren dunkle Objekte über Asphalt besser zu erkennen (Annotation) und automatisch zu finden (CNNs) als über Wiese (vgl. untere Person im IR-Bild in Abb. 59). Die Detektionsleistung der spezialisierten Ketten war hier dem Menschen überlegen. So konnten Fehler in der Annotation entdeckt und behoben werden<sup>61</sup>. Die ortsbezogene Auswertung (Abb. 62) bestätigt diese Vermutung. So ist auch hier eine Abflachung der F2-Metrik ab Wegpunkt WP7 zu beobachten.
- Die Spezialisierung führt zur gewünschten Adaption an den Edge-Case (Dämmerung) und an den Corner-Case (Restlicht). Dies geht jedoch zu Kosten der Leistung im nominalen Betrieb, d.h. die Leistung der Ketten bricht für normale Belichtungsverhältnisse ein (vgl. Abb. 61 und Hervorhebungen in Tabelle 7).
  - Im Gegensatz zu generisch trainierten Ketten werden häufig nicht die Personen selbst, sondern zusätzlich deren dunkle Schatten erkannt.
  - Gerade bei hellem Untergrund wie Schnee, werden die gesuchten Objekte (Personen, Autos) nicht erkannt (Recall). Bei kleinen Netzen kommt es zudem aufgrund der stärkeren Adaption häufig zu Fehlalarmen (FP).

---

<sup>61</sup> U.a. ist die „rote-Detektion“ der eo-night-tiny-Kette in Abb. 61 ist kein FP, sondern tatsächlich eine Person, wie im entsprechenden IR-Bild in Abb. 57 ersichtlich.



## Modellbildung

Für den Einsatz spezialisierter EO-Nacht-Ketten lässt sich damit folgern, dass der Einsatzraum sehr gezielt modelliert werden muss.

Hierfür wurde das folgende BN in Abb. 61 eingesetzt. Im Knoten „*Environmental Adaption*“ wird dabei primär die Zusammensetzung des „Dämmerung“-Trainingssets berücksichtigt (hoher Anteil von Twilight und Night). Der Knoten „*EO Suitability*“ dient zur Abbildung der Sensor-Tauglichkeit. Mit dieser übersichtlichen Struktur konnten komplexe Zusammenhänge wie die oberflächenabhängige Restlicht-Nutzbarkeit modelliert werden. Entscheidet ist dabei der Knoten „*Trustworthiness*“. Durch Vorgabe einer geringen bedingten Wahrscheinlichkeit (CPT) bei niedriger „*Environmental Adaption*“ und gleichzeitig hoher „*Data Usability*“ lässt sich der gewünschte, enge Betriebsbereich einstellen.

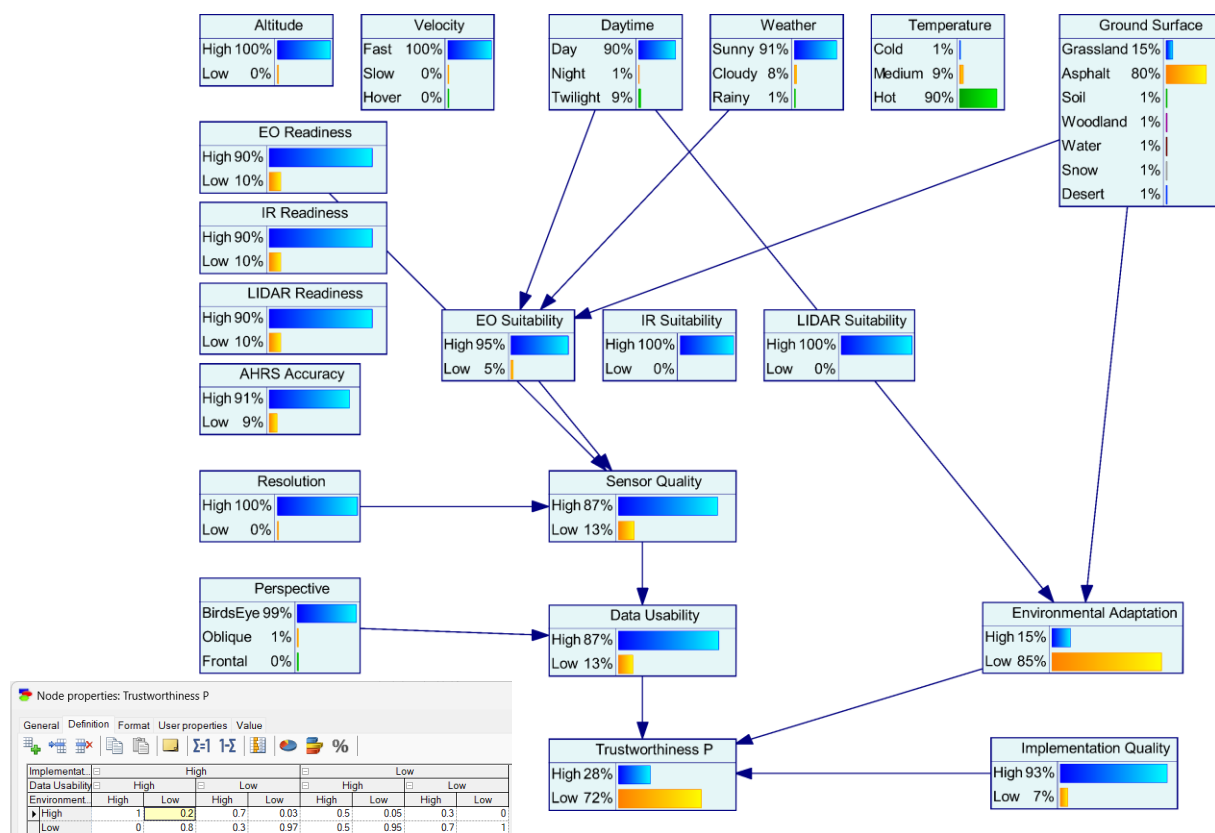

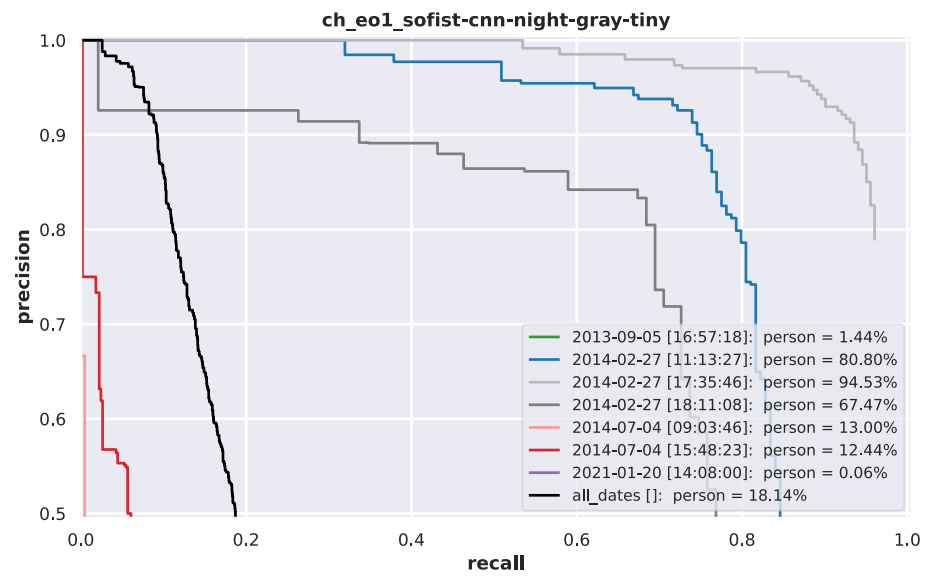




Abb. 60: Modellierung der spezialisierten EO-Ketten für den dedizierten Einsatz bei Restlicht, mit CPT (links).

Wie in Abb. 62 dargestellt, konnte mit diesen BNs der tatsächliche Kettenleistungsverlauf der EO-Nacht-Ketten für Dämmerung und Restlicht sowohl über Asphalt (WP1-WP7) als auch über Gras (WP8-WP16) treffend vorhergesagt werden. Gleichzeitig fällt die vorhergesagte Kettenleistung jenseits des geplanten Einsatzraum gering aus, so dass andere Ketten präferiert werden können. Der hohe Modellierungsfehler (2014-02-27 [11:13:27]) wird durch eine ungewöhnlich, hohe Kettenleistung bei guter Belichtung hervorgerufen. Eine Anhebung der CPTs zugunsten guter Belichtungsverhältnisse würde möglicherweise bei anderen tagsüber durchgeführten Flugversuchen zu Modellierungsfehlern und Überschätzung führen. Aufgrund der Rückfallketten (eo-generic, ir-generic) sollten zuverlässigere und weniger riskante Alternativen verfügbar sein.



**Abb. 61:** Spezialisierte EO-Ketten für den Einsatz bei Restlicht (oben: YOLOv4-CSP, unten: YOLOv4-tiny): Precision-Recall-Kurven mit AP (links) und Detektionsbeispiele (rechts): 2013-09-05 (links-oben), 2014-02-27 [17:35:46] (rechts-oben), 2014-07-04 [15:48:23] (links-unten), 2021-01-20 (rechts-unten).




Abb. 62: Leistungsverläufe spezialisierter EO-Restlicht-Ketten über Straße (WP1-WP7) und Wiese (WP8-WP16): Detektionsleistung (oben) und Modellierungsfehler (unten).



**Tabelle 7:** Ergebnisse für spezialisierte EO-Restlicht-Ketten (Threshold = 0,5, IOU = 0,4, Class = Person) mit folgendem Bewertungsschema:  
 unzureichend = rot [0,0 ; 0,4[ ... kritisch = orange [0,4 ; 0,7[ ... ausreichend = grau [0,7 ; 0,8[ ... gut = hell-grün [0,8 ; 0,9[ ... sehr gut = dunkel-grün [0,9 ; 1.0]

<i>Chain</i>	<i>Date</i>	<i>AP</i>	<i>F1</i>	<i>F2</i>	<i>F0.5</i>	<i>GT</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>Prec.</i>	<i>Recall</i>
<i>ch_eo-night</i>	2013-09-05 [16:57:18]	0,00	0,01	0,00	0,01	292	1	12	291	0,08	0,00
	2014-02-27 [11:13:27]	0,29	0,45	0,34	0,66	169	49	2	120	0,96	0,29
	2014-02-27 [17:35:46]	0,87	0,90	0,89	0,91	202	178	17	24	0,91	0,88
	2014-02-27 [18:11:08]	0,35	0,52	0,41	0,71	95	34	2	61	0,94	0,36
	2014-07-04 [09:03:46]	0,04	0,13	0,09	0,24	426	31	23	395	0,57	0,07
	2014-07-04 [15:48:23]	0,06	0,17	0,12	0,24	494	53	95	441	0,36	0,11
	2021-01-20 [14:08:00]	0,00	0,00	0,00	0,00	3352	0	5	3352	0,00	0,00
	<i>All-Dates [2013-2021]</i>	0,11	0,21	0,15	0,36	2785	347	165	2438	0,68	0,12
<i>ch_eo-night-tiny</i>	2013-09-05 [16:57:18]	0,01	0,06	0,05	0,10	288	11	58	277	0,16	0,04
	2014-02-27 [11:13:27]	0,73	0,82	0,77	0,86	169	126	14	43	0,90	0,75
	2014-02-27 [17:35:46]	0,93	0,91	0,93	0,89	202	191	26	11	0,88	0,95
	2014-02-27 [18:11:08]	0,61	0,74	0,70	0,78	95	65	16	30	0,80	0,68
	2014-07-04 [09:03:46]	0,04	0,16	0,12	0,23	426	44	90	382	0,33	0,10
	2014-07-04 [15:48:23]	0,07	0,21	0,17	0,29	494	73	120	421	0,38	0,15
	2021-01-20 [14:08:00]	0,00	0,01	0,01	0,01	3352	17	931	3335	0,02	0,01
	<i>All-Dates [2013-2021]</i>	0,16	0,27	0,22	0,35	2779	537	668	2242	0,45	0,19
<i>ch_eo-generic</i>	2014-02-27 [17:35:46]	0,66	0,76	0,71	0,81	202	138	25	64	0,85	0,68
	2014-02-27 [18:11:08]	0,01	0,02	0,01	0,05	95	1	0	94	1,00	0,01
	<i>All-Dates [2013-2021]</i>	0,82	0,89	0,85	0,92	2785	2322	123	463	0,95	0,83
<i>ch_ir-generic</i>	2014-02-27 [17:35:46]	0,99	0,94	0,97	0,90	248	248	33	0	0,88	1,00
	2014-02-27 [18:11:08]	0,91	0,90	0,92	0,88	194	181	29	13	0,86	0,93
	<i>All-Dates [2013-2021]</i>	0,78	0,86	0,82	0,90	3260	2614	220	646	0,92	0,80
<i>ch_eo-night - ch_eo-generic</i>	2014-02-27 [17:35:46]	0,21	0,14	0,18	0,10		40	-8		0,07	0,20
	2014-02-27 [18:11:08]	0,34	0,50	0,40	0,66		33	2		-0,06	0,35
<i>ch_eo-night - ch_ir-generic</i>	2014-02-27 [17:35:46]	-0,12	-0,04	-0,09	0,00					0,03	-0,12
	2014-02-27 [18:11:08]	-0,56	-0,38	-0,51	-0,16					0,08	-0,58
<i>ch_eo-night-tiny - ch_eo-generic-tiny</i>	2014-02-27 [17:35:46]	0,18	0,10	0,15	0,05		36	2		0,01	0,18
	2014-02-27 [18:11:08]	0,57	0,66	0,65	0,61		61	13		0,23	0,64
<i>ch_eo-night-tiny - ch_ir-generic-tiny</i>	2014-02-27 [17:35:46]	-0,06	0,00	-0,03	0,03					0,05	-0,05
	2014-02-27 [18:11:08]	-0,32	-0,11	-0,21	-0,02					0,04	-0,29

### 9.2.3 Spezialisierte EO-Ketten zur Optimierung (Edge-Case)

Je nach Einsatzzweck reicht für manche Anwendungen eine akzeptable oder ausreichend gute Detektionsleistung (Edge-Cases: [0,7 ; 0,8]) nicht aus. Für einen zuverlässigen Einsatz müsste die Kettenleistung von ausreichend nach gut/sehr gut oder von gut nach sehr gut angehoben werden.

Es wurde daher untersucht, ob eine Optimierung durch Adaption nur für sehr schwierige Sensor- und Umweltbedingungen (Corner-Case) gelingt oder ob auch bei Edge-Cases eine Verbesserung der Leistung erzielt werden kann. Hierfür wären die folgenden Optimierungen denkbar:

- Training für bestimmte Perspektiven
- Spezialisierung hinsichtlich dedizierter Auflösungen bzw. GSDs, um auch kleine Objekte besser zu detektieren („*tiny object detection*“, [ToWu22, XWYY22])
- Training auf dedizierte Vorder- oder Hintergründe<sup>62</sup>


Exemplarisch wurde im Rahmen dieser Arbeit untersucht, inwieweit eine Anpassung an homogene Hintergründe oder Oberflächen möglich ist. Hierfür wurden aus dem Trainingsdatensatz verschneite Winterszenen für das Transferlernen ausgewählt.

Wie in den Stichproben der Erkennung links in Abb. 63 dargestellt und in Tabelle 8 quantifiziert, liefern generische EO-Ketten eine mindestens ausreichende und teils gute Detektionsleistung bei schneebedecktem Hintergrund. Deren Leistung konnte jedoch mit dem Schnee-Trainingsset nochmals gesteigert werden (rechts in Abb. 63):







- Im Vergleich zu generischen EO-Ketten wurde eine **Verbesserung** des F2-Scores von **bis zu etwa 7 % bzw. 4 %** erreicht werden (Tabelle 8).
- Die Leistung spezialisierter EO-Schnee-Ketten ist fast gleichauf mit der Leistung generischer IR-Ketten.
- Größere EO-Schnee-Netze erzielten im angedachten Einsatzraum (Schnee, 2021-01-20 [14:08:00]) bessere Ergebnisse als kleine Netze. Dies wird im Knoten „*Implementation Quality*“ der BNs (vgl. Abb. 60) berücksichtigt und spiegelt sich im Verlauf der vorhergesagten Kettenleistung wider.
- Die Kettenleistung degeneriert für nicht schneebedeckte Umgebungen. Der Leistungsabfall ist jedoch nicht so stark ausgeprägt ist wie bei EO-Dämmerungs-Ketten (vgl. Leistungsverläufe Abb. 65 und Abb. 62).
- Wie in den Stichproben (Abb. 63) erkennbar, wurde zudem die Lokalisierung (Position, Größe) im Vergleich zur Annotation (rot-grün) deutlich verbessert und zu generischer Ketten (rot-rot, links-rechts) präzisiert.

---

<sup>62</sup> Vordergründe beziehen sich auf die gesuchten Objekte, im Rahmen des gestellten Unfallszenarios also auf Personen oder Fahrzeuge. Da hier keine eindeutigen Aussagen getroffen werden können, z.B. Farbe der Kleidung oder Fahrzeugtyp, wurde dieser Fall nicht weiter untersucht. Im Rahmen militärischer Einsatzzwecke wie der Aufklärung, wäre aber ein Training auf Uniformen oder Tarnfarben/-muster von Fahrzeugen/Tarnnetzen interessant.





**Abb. 63:** Vergleich zwischen generischer EO-Kette (links) und optimierter EO-Schnee-Kette (rechts).



**Abb. 64:** Spezialisierte EO-Schnee-Ketten zur Optimierung bei homogenen Oberflächen (oben: YOLOv4-CSP, unten: Precision-Recall-Kurven mit AP (links) und Detektionsbeispiele (rechts): 2013-09-05 (links-oben), 2014-02-27 [17:35:46] (rechts-oben), 2014-07-04 [15:48:23] (links-unten), 2021-01-20 (rechts-unten).





**Abb. 65:** Leistungsverläufe spezialisierten EO-Schnee-Ketten über Straße (WP1-WP7) und Wiese (WP8-WP16): Detektionsleistung (oben) und Modellierungsfehler (unten).

**Tabelle 8:** Ergebnisse für spezialisierte EO-Schnee-Ketten (Threshold = 0,5, IOU = 0,4, Class = Person) mit folgendem Bewertungsschema:  
 unzureichend = rot [0,0 ; 0,4[ ... kritisch = orange [0,4 ; 0,7[ ... ausreichend = grau [0,7 ; 0,8[ ... gut = hell-grün [0,8 ; 0,9[ ... sehr gut = dunkel-grün [0,9 ; 1.0]


<i>Chain</i>	<i>Date</i>	<i>AP</i>	<i>F1</i>	<i>F2</i>	<i>F0.5</i>	<i>GT</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>Prec.</i>	<i>Recall</i>
<i>ch_eo-snow</i>	2013-09-05 [16:57:18]	0,71	0,78	0,76	0,80	292	219	52	73	0,81	0,75
	2014-02-27 [11:13:27]	0,39	0,61	0,59	0,64	169	97	50	72	0,66	0,57
	2014-02-27 [17:35:46]	0,02	0,05	0,03	0,11	202	5	0	197	1,00	0,02
	2014-02-27 [18:11:08]	0,00	0,00	0,00	0,00	95	0	0	95	0,00	0,00
	2014-07-04 [09:03:46]	0,35	0,58	0,57	0,59	426	239	157	187	0,60	0,56
	2014-07-04 [15:48:23]	0,34	0,55	0,51	0,59	494	244	152	250	0,62	0,49
	2021-01-20 [14:08:00]	0,86	0,91	0,89	0,92	3352	2970	227	382	0,93	0,89
	<i>All-Dates [2013-2021]</i>	0,53	0,67	0,62	0,73	2785	1660	497	1125	0,77	0,60
<i>ch_eo-snow-tiny</i>	2013-09-05 [16:57:18]	0,33	0,51	0,44	0,59	292	120	63	172	0,66	0,41
	2014-02-27 [11:13:27]	0,76	0,82	0,81	0,82	169	137	29	32	0,83	0,81
	2014-02-27 [17:35:46]	0,00	0,00	0,00	0,00	202	0	0	202	0,00	0,00
	2014-02-27 [18:11:08]	0,00	0,00	0,00	0,00	95	0	0	95	0,00	0,00
	2014-07-04 [09:03:46]	0,51	0,70	0,70	0,70	426	298	124	128	0,71	0,70
	2014-07-04 [15:48:23]	0,38	0,56	0,50	0,64	494	230	95	264	0,71	0,47
	2021-01-20 [14:08:00]	0,81	0,87	0,85	0,90	3352	2791	266	561	0,91	0,83
	<i>All-Dates [2013-2021]</i>	0,54	0,67	0,62	0,73	2784	1637	468	1147	0,78	0,59
<i>ch_eo-generic</i>	2021-01-20 [14:08:00]	0,79	0,88	0,84	0,93	3352	2707	76	645	0,97	0,81
	<i>All-Dates [2013-2021]</i>	0,82	0,89	0,85	0,92	2785	2322	123	463	0,95	0,83
<i>ch_ir-generic</i>	2021-01-20 [14:08:00]	0,90	0,93	0,92	0,95	3887	3513	128	374	0,96	0,90
	<i>All-Dates [2013-2021]</i>	0,78	0,86	0,82	0,90	3260	2614	220	646	0,92	0,80
<i>ch_eo-snow - ch_eo-generic</i>	2021-01-20 [14:08:00]	<b>0,07</b>	<b>0,02</b>	<b>0,06</b>	<b>-0,01</b>		263	151		-0,04	0,08
<i>ch_eo-snow - ch_ir-generic</i>	2021-01-20 [14:08:00]	-0,03	-0,03	-0,02	-0,03					-0,04	-0,02
<i>ch_eo-snow-tiny - ch_eo-generic-tiny</i>	2021-01-20 [14:08:00]	<b>0,04</b>	<b>0,02</b>	<b>0,02</b>	<b>0,02</b>		60	-70		0,02	0,02
<i>ch_eo-snow-tiny - ch_ir-generic-tiny</i>	2021-01-20 [14:08:00]	-0,08	-0,06	-0,07	-0,05					-0,04	-0,08

### 9.2.4 Spezialisierte IR-Ketten für schwierige Bedingungen (Corner-Case)

Die Auswertung der Testreihen und der Detektionsergebnisse bestätigte, dass die Leistung generisch trainierter Ketten in Abhängigkeit von den Umgebungsparametern variiert. Wetter, Temperatur, Lichtverhältnisse, aber auch die Art, Farbe oder Rauheit der Oberfläche beeinflussen die Bildqualität.

Neben offensichtlichen Abhängigkeiten wie der Reichweitenbegrenzung von aktiven Sensoren und Abstandssensoren oder der Tageslichtabhängigkeit von EO-Kameras wurden auch komplexere LWIR-Zusammenhänge gefunden und untersucht. So besteht ein Zusammenhang zwischen der Verwendbarkeit von Sensordaten, der Temperatur und der Art des Hintergrunds:

- Thermische LWIR-Bilder sind bei hohen Temperaturen im Sommer auf homogenen Oberflächen (einschließlich Asphalt) gut auswertbar.
- Im Gegensatz dazu sind IR-Bilder an heißen Tagen über unstrukturiertem Gelände oder Vegetation, Gras kaum oder nicht auswertbar und führen zu schlechten Ergebnissen.



**Abb. 66:** Vergleich generischer EO-/LWIR-Ketten (links, mittig) sowie spezialisierter IR-Vegetations-Ketten (rechts) bei Flügen an heißen Tagen: Die Tauglichkeit der LWIR-Sensoren ist dabei stark von der Art des Untergrundes abhängig: a) gute Ergebnisse über Asphalt (homogene Temperatur des Hintergrundes) b) unzuverlässige Detektionen über Vegetation (inhomogene Temperaturverteilung des Untergrundes).

Der Vergleich generischer EO- und LWIR-Ketten für Flüge an heißen Tagen (Abb. 66) veranschaulicht die eingeschränkte, zeit-ortsgebundene Tauglichkeit generischer IR-Ketten. Für diese Umweltbedingungen wären EO-Ketten die bevorzugte Wahl. Aus operationeller Sicht ist jedoch ein erweiterter IR-Einsatzraum auch an heißen Tagen u.a. aus den folgenden Gesichtspunkten erstrebenswert:

- Unter erschwerten, militärischen Einsatzbedingungen ist neben witterungsbedingten Störungen<sup>63</sup> mit Staub, Schmutz, Verschleiß (Objektive) oder Beschuss zu rechnen. Der Ausfall von Sensoren kann also nicht ausgeschlossen werden.
- Zur Erreichung der Einsatzziele kann die feste Vorgabe eines Sensortyps nötig sein. So sind IR-Sensoren bei Aufklärungsmissionen (Tarnung, Infrarot-Signaturen) oder im Katastrophenschutz (Lokalisierung von Bränden, Austritt von Flüssigkeiten, Gasen) häufig die präferierten Missionssensoren.
- Bei kleinen UAVs kann aus Kostengründen oder aufgrund erschwelter Randbedingungen (Größe, Gewicht, Energie) häufig nur ein Missionssensor integriert werden.

Daher wurden IR-Ketten speziell für diese anspruchsvollen LWIR-Bedingungen separat trainiert und in das SPMS-Framework eingebunden. Dazu wurden die Basisnetze (COCO) mithilfe gefilterter Trainingsdaten aus heißen Tagen (hohe Temperaturen, Sonneneinstrahlung) und mit inhomogenen Untergründen (Wiesen, Sträucher, Büsche) angepasst.

Stichproben der Ergebnisse sind in Abb. 66 (rechts) und in Abb. 69 dargestellt. Aufgrund der Spezialisierung über inhomogenen Untergrund (Vegetation) ist hierbei im Gegensatz zu den bisherigen Auswertungen zusätzlich eine genauere, ortsbezogene Betrachtung der Precision-Recall-Kurven (Abb. 67), der Leistungsverläufe (Abb. 70) und der Ergebnisse (Tabelle 9) nötig:

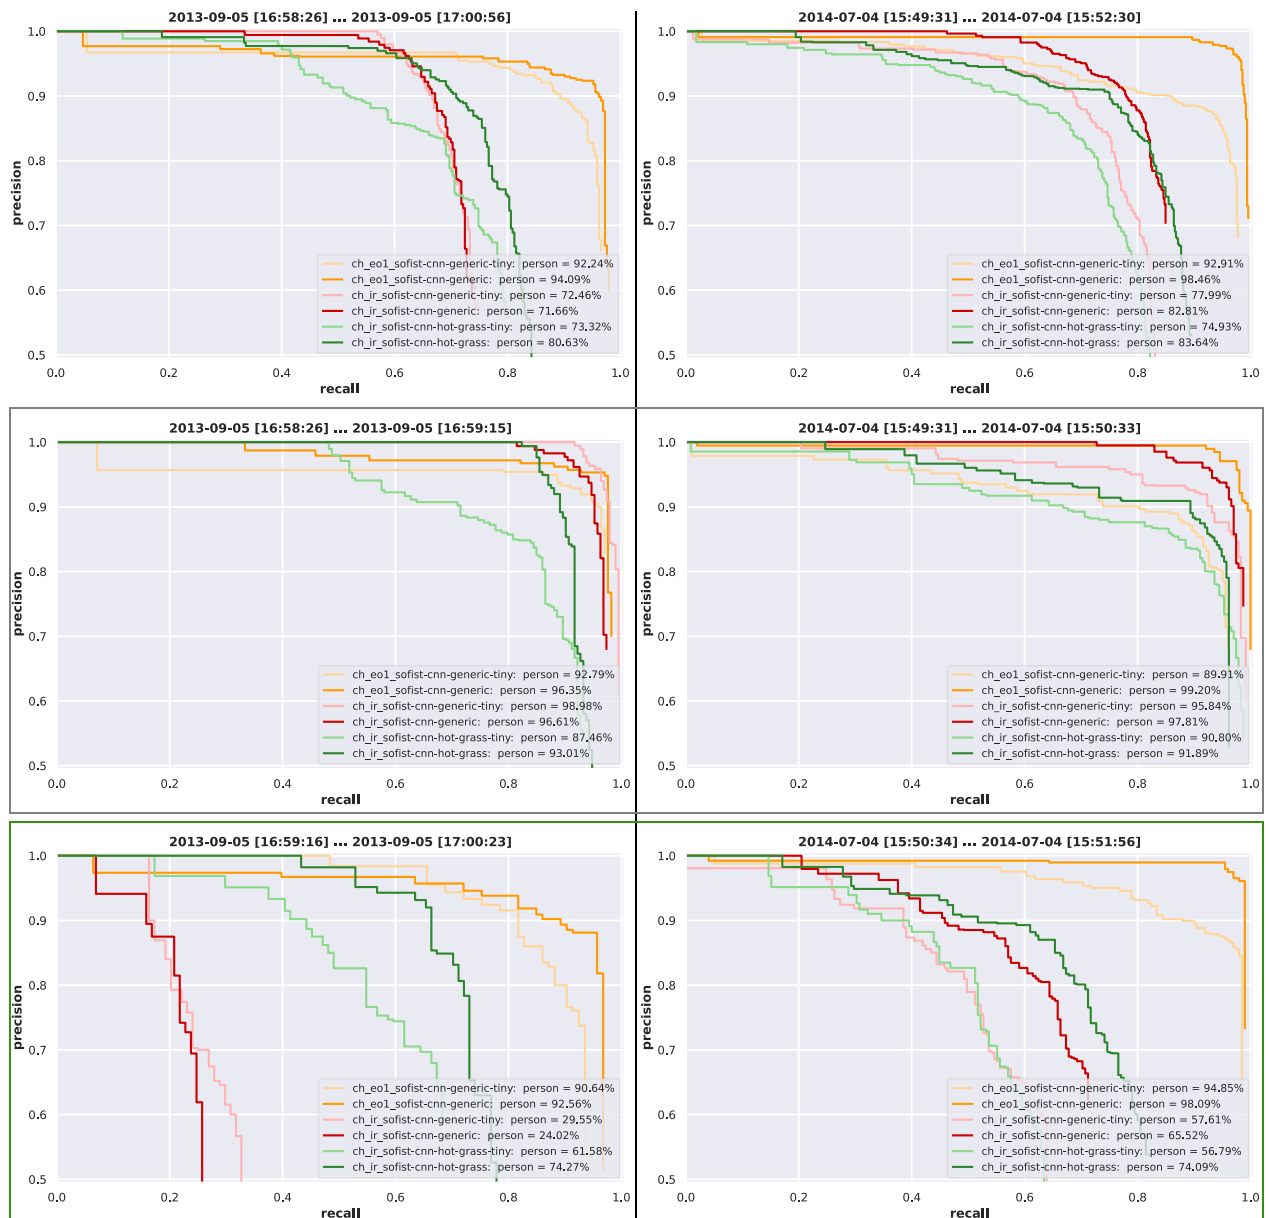
- Im Vergleich zu generischen IR-Ketten ist innerhalb des angedachten Einsatzraums (heiße, sonnige Tage und über Vegetation) eine deutliche **Leistungsverbesserung** von **bis zu 51%** („tiny“ **bis zu 14%**) feststellbar. Wie in der ortsdifferenzierten Auswertung (Abb. 67) ersichtlich, sind jedoch generische IR-Ketten über homogenen Flächen (z.B. Straße) zu bevorzugen.
- Der prinzipielle Nachteil von LWIR-Sensoren an sonnigen Tagen über inhomogenem Untergrund kann auch durch Spezialisierung nicht vollumfänglich kompensiert werden. Die Leistung generischer EO-Ketten an sonnigen Tagen über Vegetation bleibt unerreicht. Falls einsetzbar, sind EO-Ketten hier weiterhin zu präferieren.
- Größeren IR-Vegetations-Ketten erzielten gerade im Einsatzraum eine bessere Leistung als kleinere, effizientere Netze (vgl. Leistungsverläufe in Abb. 70).
- Außerhalb des Einsatzraums ist die Degeneration der Kettenleistung im Vergleich zu den bisher dargestellten spezialisierten Ketten gering. Spezialisierte IR-Vegetations-Ketten könnten daher eine Alternative zu generischen IR-Ketten darstellen. Die Verschlechterung über Straße wird durch eine deutliche Verbesserung der Kettenleistung über Vegetation ausgeglichen.

---

<sup>63</sup> Regen, Nebel, Vereisung, etc.



- Das Maximum der Leistung hängt vom gewählten Kettenschwellwert (Threshold) ab. Eine adaptive Kopplung der Schwellwerte an die vorhergesagte Kettenleistung (BN) könnte eine zusätzliche Reduzierung der FPs und/oder mehr TPs ermöglichen.
- Wie in den Stichproben (Abb. 66) erkennbar, wurde die Lokalisierung (Position, Größe) im Vergleich zur Annotation deutlich (rot-grün) und zu generischen Ketten merklich verbessert (rot-rot, mittig-rechts).



**Abb. 67:** Ortsbezogener Vergleich der Leistung zwischen IR-Vegetations-Ketten und generischen Ketten (EO, IR) anhand der Precision-Recall-Kurve. Aufteilung des gesamten Flugversuchs (oben) erfolgte gemäß Flugplan in ein Straßensegment (mittig, WP1-WP7) und in ein Wiesensegment (unten, WP8-WP16). Auswertung erfolgte für die heißen, sonnigen (Spät-)/Sommerflüge: 2013-09-05 [16:57:18] (links), 2014-07-04 [15:48:23] (rechts).

### Modellbildung

Zur Vorhersage der ortsabhängigen Kettenleistung wurde das BN aus Abb. 68 eingesetzt. Im Knoten „*Environmental Adaption*“ wird dabei der kausale Zusammenhang zwischen

Temperatur und Oberfläche hergestellt, welcher auch die Zusammensetzung des Trainingssets und damit die Spezialisierung widerspiegelt (hoher Anteil von Vegetation an heißen Tagen).

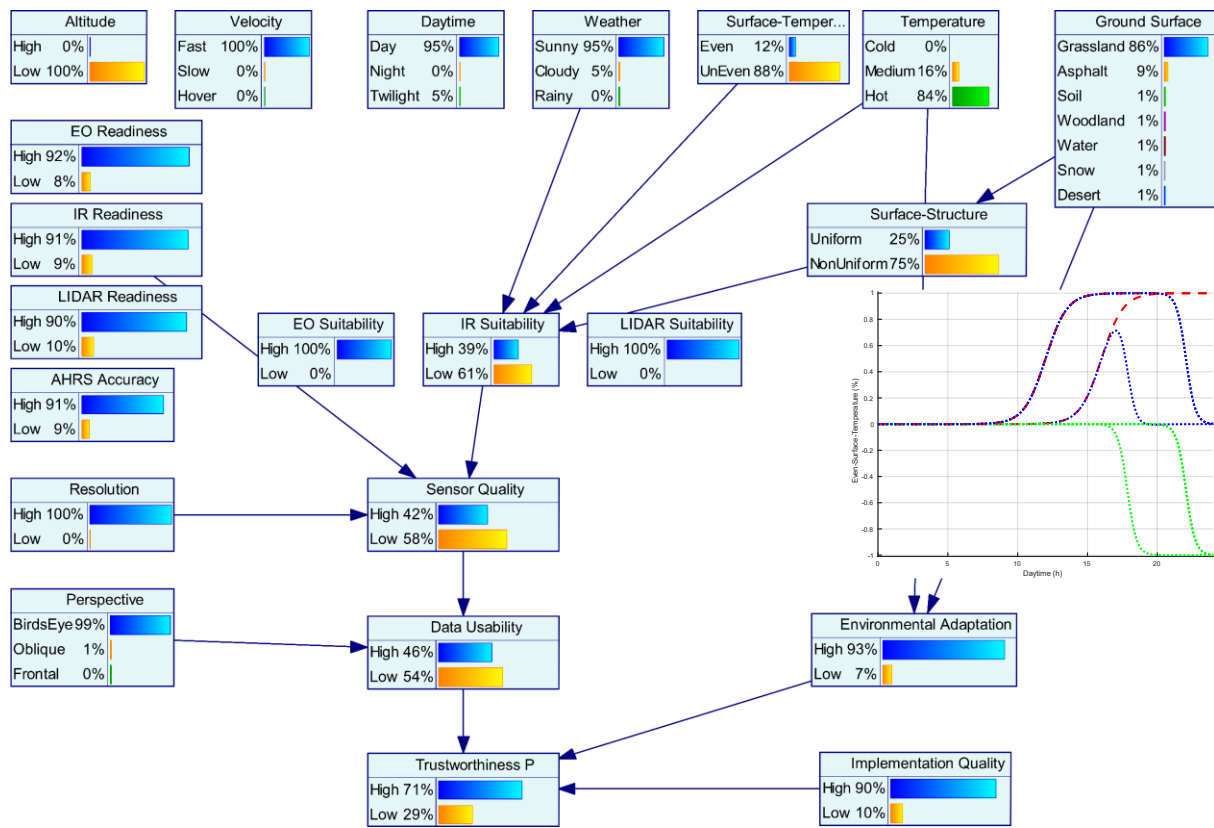






Abb. 68: Modellierung spezialisierter IR-Vegetations-Ketten für den ortsdifferenzierten Einsatz an heißen Tagen.

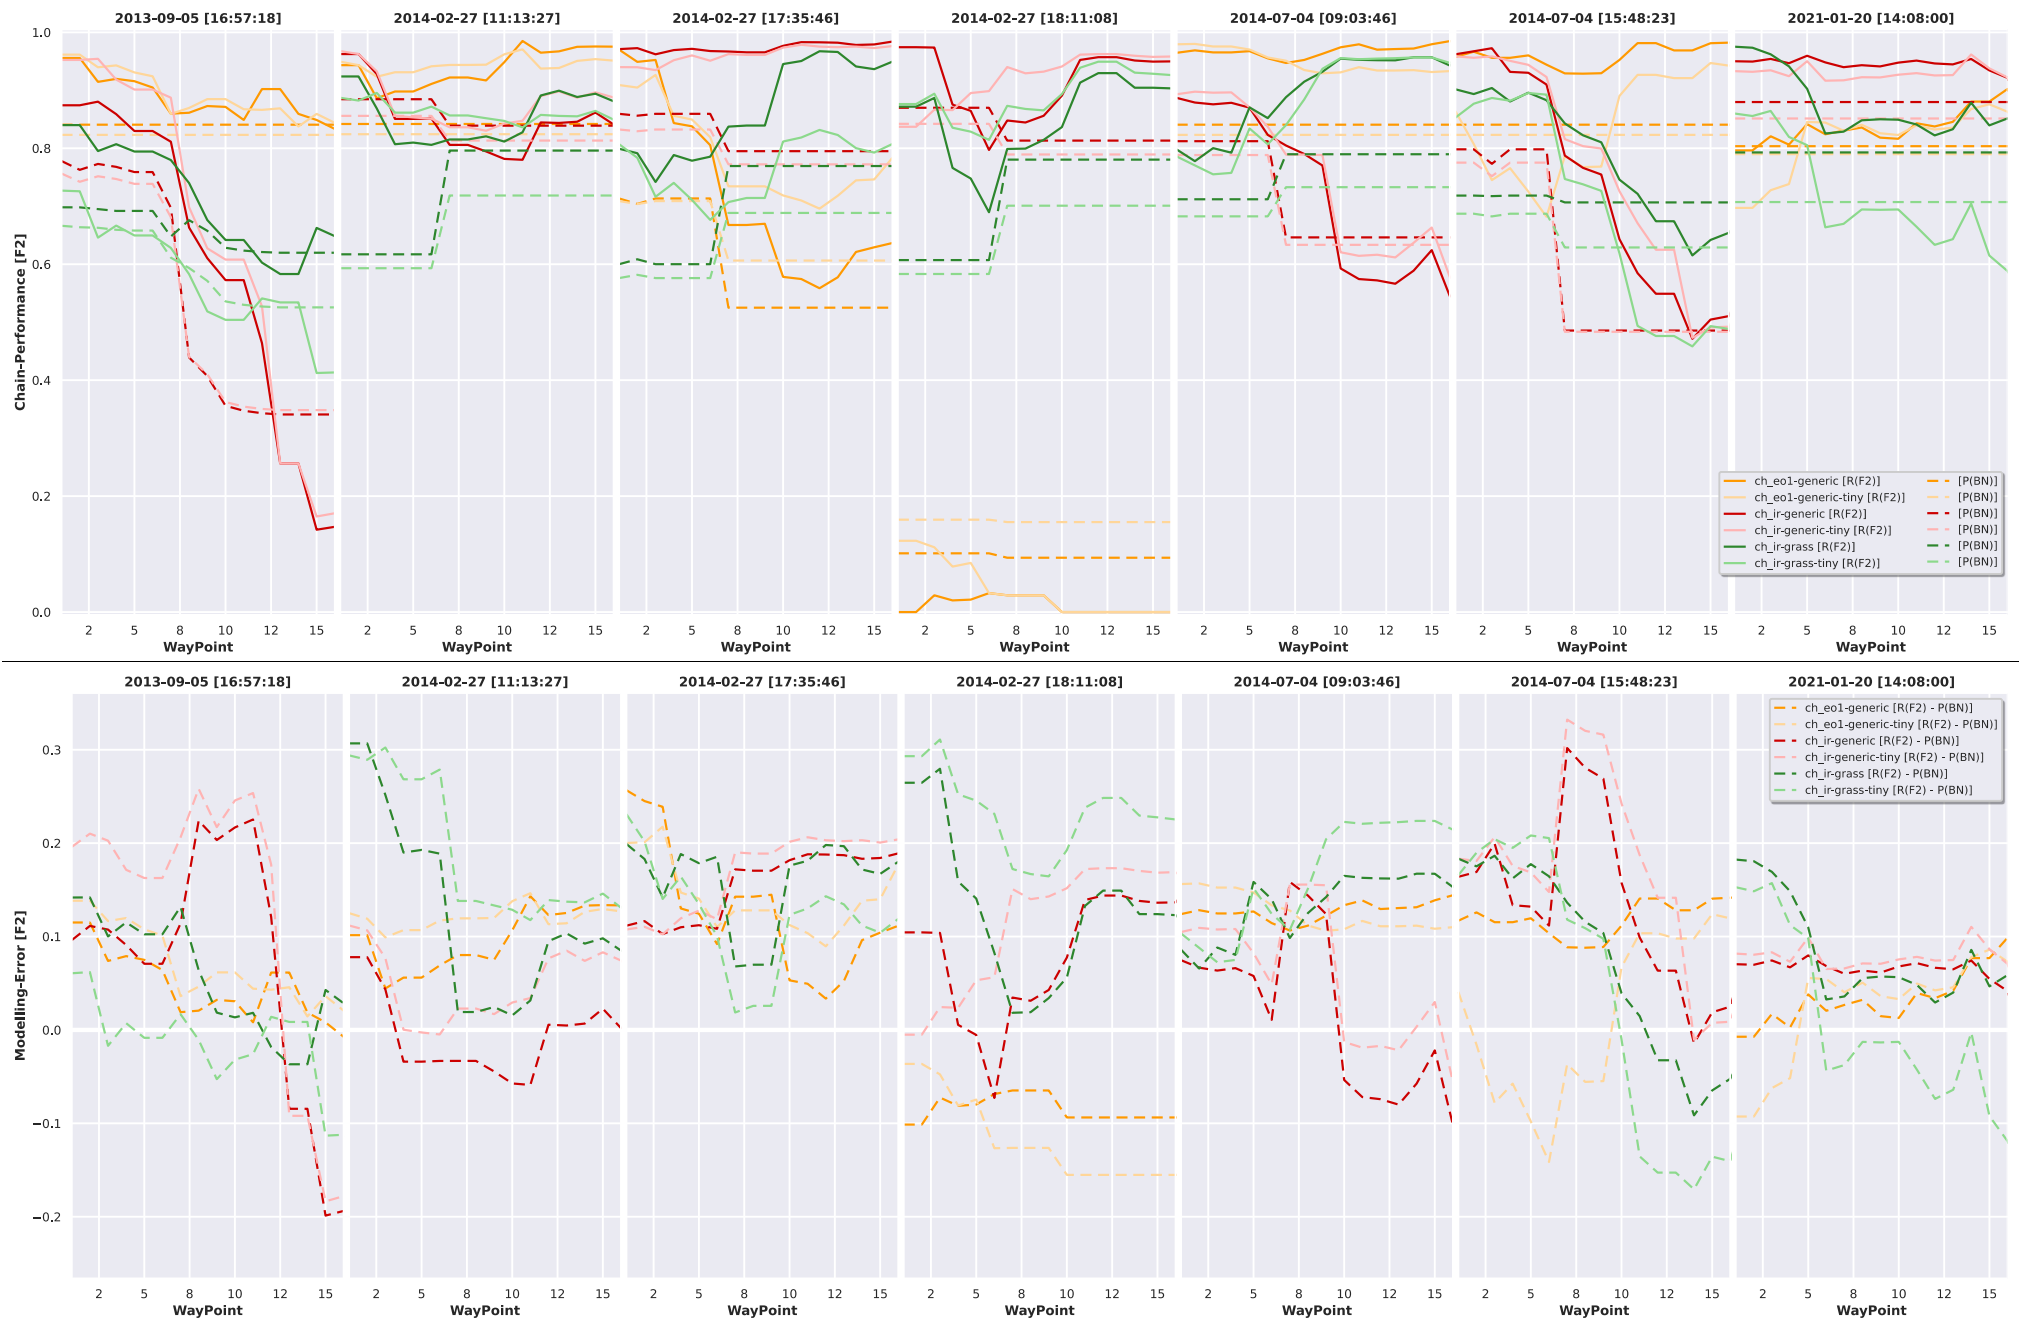
Über die Knoten „Surface-Structure“ und „Surface-Temperature“ wird die Beeinflussung der „IR-Suitability“ bei inhomogener bzw. homogener Temperaturverteilung des Untergrundes im Zusammenspiel mit Wetter und Temperatur modelliert. Zusätzlich wird durch den Knoten „Surface-Structure“ eine Vereinfachung der CPTs (Reduzierung der Parameter/Spalten) erreicht. Die Erwärmung bzw. Abkühlung der Oberfläche ist zudem als Schiefe-Funktion<sup>64</sup> (rechts in Abb. 68) über der Uhrzeit modelliert (hybrides BN), wobei die Parameter der Kurve abhängig vom jeweiligen Sonnenaufgang und -untergang sind.

Wie in Abb. 70 dargestellt, konnte mit diesem hybriden BN der ortsabhängige Kettenleistungsverlauf der IR-Vegetation-Ketten sowohl über Asphalt (WP1-WP7) als auch über Gras (WP8-WP16) sinnvoll vorhergesagt werden.

<sup>64</sup> Die eingesetzte Schiefe-Funktion bildet den Sachverhalt ab, dass die Erwärmung über den Tag langsamer verläuft als die Abkühlung in den Abendstunden. Ebenso ist die Erwärmung im Sommer deutlich ausgeprägter und schneller als im Winter.



**Abb. 69:** Spezialisierte IR-Vegetations-Ketten (oben: YOLOv4-CSP, unten: YOLOv4-tiny): Precision-Recall-Kurven mit AP (links) und Detektionsbeispiele (rechts): 2013-09-05 (links-oben), 2014-02-27 [17:35:46] (rechts-oben), 2014-07-04 [15:48:23] (links-unten), 2021-01-20 (rechts-unten).



**Abb. 70:** Leistungsverläufe spezialisierten IR-Vegetations-Ketten über Straße (WP1-WP7) und Wiese (WP8-WP16): Detektionsleistung (oben) und Modellierungsfehler (unten).

**Tabelle 9:** Ergebnisse für spezialisierte IR-Vegetations-Ketten (Threshold = 0,5, IOU = 0,4, Class = Person).

<i>Chain</i>	<i>Date</i>	<i>AP</i>	<i>F1</i>	<i>F2</i>	<i>F0.5</i>	<i>GT</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>Prec.</i>	<i>Recall</i>
<i>ch_ir-grass</i>	2013-09-05 [16:57:18]	0,65	0,78	0,70	0,86	330	219	15	111	0,94	0,66
	grass [16:59:16-17:00:23]	0,65	0,75	0,70	0,82	104	69	10	35	0,87	0,66
	2014-02-27 [11:13:27]	0,84	0,85	0,86	0,83	193	169	36	24	0,82	0,88
	2014-02-27 [17:35:46]	0,83	0,86	0,87	0,85	248	218	40	30	0,84	0,88
	2014-02-27 [18:11:08]	0,81	0,84	0,85	0,83	194	166	37	28	0,82	0,86
	2014-07-04 [09:03:46]	0,86	0,86	0,88	0,83	494	445	99	49	0,82	0,90
	2014-07-04 [15:48:23]	0,72	0,82	0,78	0,87	545	408	43	137	0,90	0,75
	grass [15:50:34- 15:51:56]	0,59	0,72	0,65	0,81	205	126	17	79	0,88	0,61
2021-01-20 [14:08:00]	0,86	0,91	0,88	0,94	3887	3372	164	515	0,95	0,87	
<i>All-Dates [2013-2021]</i>	0,80	0,86	0,85	0,88	3267	2729	334	538	0,89	0,84	
<i>ch_ir-grass-tiny</i>	2013-09-05 [16:57:18]	0,49	0,65	0,55	0,78	330	165	16	165	0,91	0,50
	grass [16:59:16-17:00:23]	0,44	0,60	0,50	0,74	104	47	6	57	0,89	0,45
	2014-02-27 [11:13:27]	0,84	0,81	0,86	0,77	193	172	60	21	0,74	0,89
	2014-02-27 [17:35:46]	0,68	0,77	0,77	0,77	248	192	56	56	0,77	0,77
	2014-02-27 [18:11:08]	0,86	0,86	0,89	0,84	195	178	39	17	0,82	0,91
	2014-07-04 [09:03:46]	0,85	0,82	0,87	0,77	494	451	156	43	0,74	0,91
	2014-07-04 [15:48:23]	0,64	0,76	0,71	0,81	545	369	61	176	0,86	0,68
	grass [15:50:34- 15:51:56]	0,42	0,58	0,49	0,73	205	90	13	115	0,87	0,44
2021-01-20 [14:08:00]	0,64	0,77	0,69	0,86	3887	2532	169	1355	0,94	0,65	
<i>All-Dates [2013-2021]</i>	0,69	0,79	0,76	0,82	3268	2411	457	857	0,84	0,74	
<i>ch_eo-generic</i>	2013-09-05 [16:57:18]	0,85	0,90	0,89	0,92	292	257	19	35	0,93	0,88
	2014-07-04 [15:48:23]	0,96	0,97	0,97	0,97	494	479	16	15	0,97	0,97
	<i>All-Dates [2013-2021]</i>	0,82	0,89	0,85	0,92	2785	2322	123	463	0,95	0,83
<i>ch_ir-generic</i>	2013-09-05 [16:57:18]	0,58	0,73	0,63	0,86	323	187	4	136	0,98	0,58
	grass [16:59:16-17:00:23]	0,15	0,27	0,19	0,46	101	16	2	85	0,89	0,16
	2014-07-04 [15:48:23]	0,71	0,81	0,75	0,89	545	391	25	154	0,94	0,72
	grass [15:50:34- 15:51:56]	0,45	0,61	0,51	0,76	205	94	10	111	0,90	0,46
<i>All-Dates [2013-2021]</i>	0,78	0,86	0,82	0,90	3260	2614	220	646	0,92	0,80	
<i>ch_ir-grass - ch_eo-generic</i>	2013-09-05 [16:57:18]	-0,20	-0,13	-0,19	-0,06		-38	-4		0,00	-0,22
	2014-07-04 [15:48:23]	-0,24	-0,15	-0,19	-0,10		-71	27		-0,06	-0,22
<i>ch_ir-grass - ch_ir-generic</i>	2013-09-05 [16:57:18]	<b>0,08</b>	<b>0,05</b>	<b>0,07</b>	<b>0,00</b>		32	11		-0,04	0,08
	grass [16:59:16-17:00:23]	<b>0,50</b>	<b>0,49</b>	<b>0,51</b>	<b>0,36</b>		53	8		-0,02	0,51
	2014-07-04 [15:48:23]	<b>0,01</b>	<b>0,01</b>	<b>0,02</b>	<b>-0,02</b>		17	18		-0,04	0,03
	grass [15:50:34- 15:51:56]	<b>0,14</b>	<b>0,12</b>	<b>0,15</b>	<b>0,05</b>		32	7		-0,02	0,16

### 9.2.5 Spezialisierte IR-Ketten zur Optimierung (Edge-Case)

Wie bereits in Abschnitt 9.2.3 für EO-Ketten gezeigt, können zur Optimierung bzw. Adaption von Ketten vergleichbare, wiederkehrende Umwelt-, Sensor- und Plattformzustände oder situative Zusammenhänge genutzt werden. Hierfür müssen Ähnlichkeiten in den Sensorbildern und der Szenerie (Vorder- zu Hintergrundgrund) gefunden werden, um ein dediziertes Trainingsdatenset ableiten zu können.

Bei niedrigen Außentemperaturen gibt es ausgeprägte Temperaturunterschiede zwischen Vorder- und Hintergrund. Häufig ist das Objekt im Vordergrund aufgrund der Körpertemperatur<sup>65</sup> oder internen Wärmequellen (beheizte Fahrzeuge, Gebäude oder Wärmeverluste von Geräten) wärmer als der kalte Unter-/Hintergrund. Im Gegensatz zu heißen Sommertagen heben sich zudem Objekte auch über Vegetation und nicht nur über homogenen Untergründen (Straße) deutlich hervor (Abb. 71). Aufgrund des hohen Kontrasts und des geringen Rauschens der Sensorbilder erzielen generische IR-Ketten im Winter durchgängig eine gute Detektionsleistung (vgl. Verlauf in Abb. 58).

Eine zusätzliche Leistungssteigerung von gut nach sehr gut ist jedoch für sicherheitskritische Anwendungen wünschenswert. Um generische Ketten zu verbessern, könnten größere Netzwerke und mehr Trainingsdaten mit hoher Variabilität verwendet werden. Allerdings ist ungewiss, ob solche Vergrößerungen den gewünschten Effekt erzielen, insbesondere ob sie nicht unerwünschte Nebenwirkungen verursachen. Die Frage, ob sich eine Verbesserung für den gewünschten Anwendungsfall (hier kalte Temperaturen) einstellt, ist ebenso schwer vorherzusagen wie der mögliche Verlust der Leistungsfähigkeit im übrigen Einsatzraum (mittlere und warme Tage). Zudem ist zu berücksichtigen, dass eine Vergrößerung der Netzwerke und Datensätze mit erheblichem Mehraufwand und Kosten verbunden ist.

Im Rahmen SPMS-Ansatzes ist hingegen der modellbasierte Einsatz kleinerer, spezialisierter Netze möglich. Ob ein gezieltes Training für dedizierte Vorder- oder Hintergründe auch für bereits gute Ketten noch eine Verbesserung bringt, ist vorhersehbar, aber gerade im Rahmen einer umfänglichen Validierung des SPMS-Konzeptes von Interesse.

Für das Training der IR-Kalt-Ketten wurden aus den 40 Flugversuchen (Tabelle 5) primär kalte Tage im Winter und vereinzelt Szenen im Herbst und Frühling am Morgen gefiltert und für das Transferlernen eingesetzt. Wie im Vergleich der Detektionen in Abb. 71 gezeigt und in Tabelle 10 zusammengefasst wird, kann die gute Leistung generischer Ketten durch ein gezieltes Training noch gesteigert werden:


- Insbesondere bei Flugversuchen, bei denen generische Ketten lediglich eine gute Detektionsleistung aufweisen, ergibt sich ein **Leistungszuwachs von 4% bis 12%** für größere CNNs und von **3% bis 12% für kleinere CNNs**.
- Bereits sehr gute Leistungen ( $> 0.90$ ) konnten nicht weiter verbessert werden.

---

<sup>65</sup> Neben der Fauna (Tiere und Menschen) besitzen auch Pflanzen und Bäume (Flora) aufgrund von Stoffwechselprozessen eine interne Körpertemperatur, die sich von der Außentemperatur unterscheidet. Im Gegensatz zu „totem“ Untergrund (Stein, Asphalt, Erde/Sand, etc.) liegt die Temperatur von Lebewesen (Fauna, Flora) daher bei kurzen, moderaten Kälteperioden i.d.R. über der Außentemperatur.



- Anhand der Precision-Recall-Kurven (Abb. 73) und der Leistungsverläufe (Abb. 74) wird deutlich, dass kleinere Netze im Vergleich zu größeren Netzen eine stärkere Spezialisierung aufweisen. Neben einer gewollten Adaption an kalte Temperaturen, ist hierbei mit einer noch stärker ausgeprägten Degeneration der Leistung außerhalb des Einsatzraums zu rechnen.
- Innerhalb ihres Einsatzraums ist die Leistung spezialisierter IR-Kalt-Ketten fast durchgängig sehr gut. Sie übertreffen dabei generische EO-Ketten teils deutlich (2021-01-20 [14:08:00]) und sind daher bei kalten Außentemperaturen generischen Ketten vorzuziehen.
- Wie in den Stichproben (Abb. 71, Abb. 73) erkennbar ist, wurde die Lokalisierungsgenauigkeit (Position, Größe) im Vergleich zur Annotation (Mensch) durchgängig übertroffen (rot -grün). Die Ortsgenauigkeit generischer IR-Ketten war bereit sehr gut und konnte nicht wesentlich verbessert werden (links-rechts, rot zu rot).



**Abb. 71:** Detektionen generischer IR-Kette (links) und spezialisierter IR-Kalt-Kette (rechts) an kalten Tagen (oben: 2014-07-04 [15:48:23], unten: 2014-02-27 [11:13:27]).

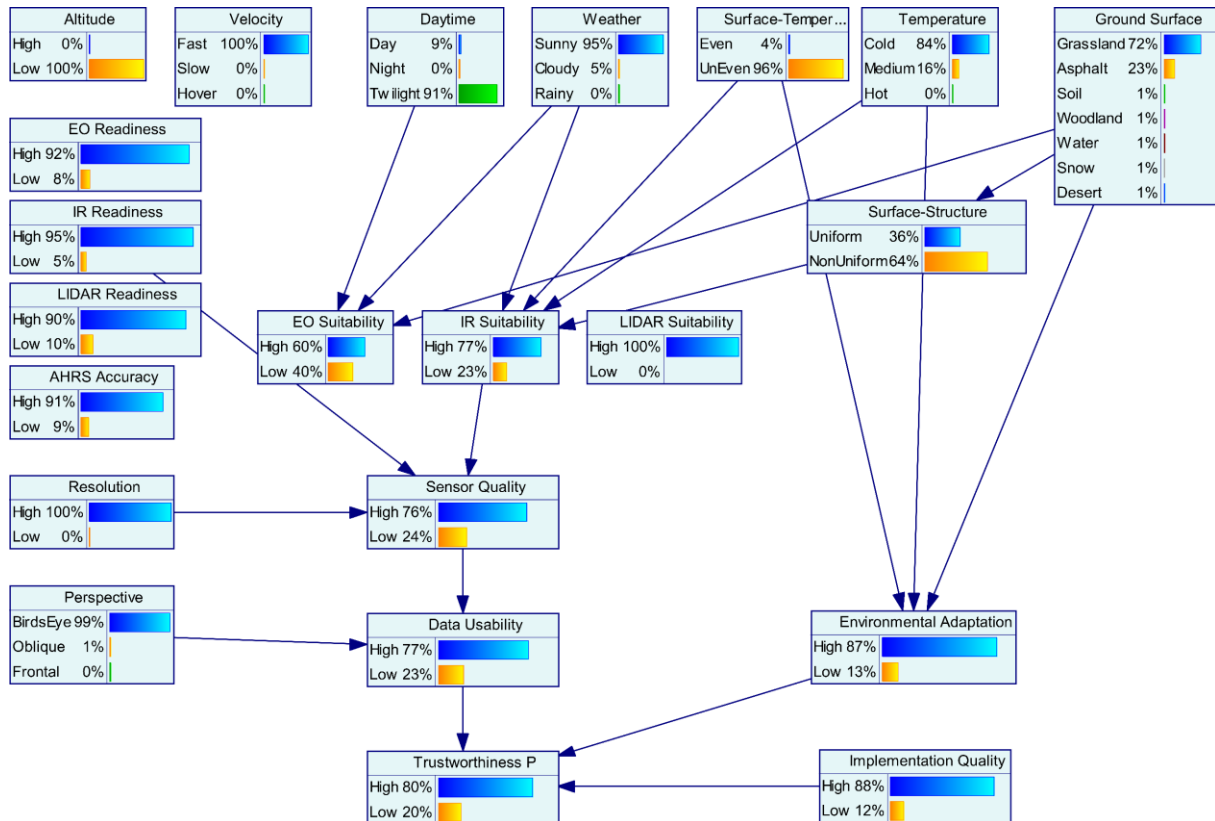
## Modellbildung

Zur Vorhersage der Kettenleistung wurden die CPTs der Knoten „*Environmental-Adaption*“ und „*Trustworthiness*“ an den neuen Einsatzraum und die Zusammensetzung des Trainingssets angepasst. Zusätzlich wurde die Struktur des BNs aus Abb. 80 geändert, um den unterschiedlichen Leistungsverlauf am Morgen und am Abend besser abzubilden. Hierfür

wurde der Knoten „Surface-Temperature“ im Knoten „Environmental-Adaption“ berücksichtigt<sup>66</sup> und über den CPT quantifiziert (Abschnitt 6.6.3).

Wie in Abb. 74 dargestellt, konnte mit diesem hybriden BN (Abb. 72) der temperatur- und tageszeitabhängige Kettenleistungsverlauf beider IR-Kalt-Ketten jahres- und tageszeitübergreifend vorhergesagt werden:




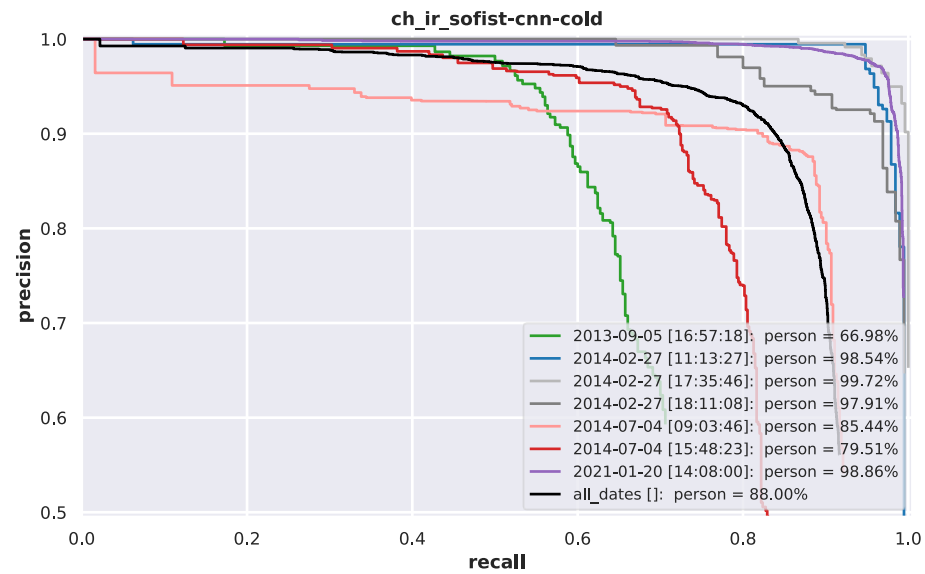
- Ganzjährig, mit einem Fehler des F2-Scores zwischen -0,2 und 0,3 und
- Innerhalb, des engeren Einsatzraum (Winter) mit einem absoluten Fehler  $< 0,1$ .





**Abb. 72:** Modellierung der IR-Kalt-Ketten für den Einsatz an kalten Tagen.

<sup>66</sup> Die Erwärmung- bzw. Abkühlung der Oberfläche wurde im hybriden Netz als Schiefe-Funktion (vgl. Abschnitt 9.2.4) über der Tageszeit angenähert. Die Kurvenparameter hängen ihrerseits vom jeweiligen Sonnenaufgang und -untergang und folglich auch von der Jahreszeit ab (rechts in Abb. 68).





**Abb. 73:** Spezialisierte IR-Kalt-Ketten (oben: YOLOv4-CSP, unten: YOLOv4-tiny): Precision-Recall-Kurven mit AP (links) und Detektionsbeispiele (rechts): 2013-09-05 (links-oben), 2014-02-27 [17:35:46] (rechts-oben), 2014-07-04 [15:48:23] (links-unten), 2021-01-20 (rechts-unten).



**Abb. 74:** Leistungsverläufe spezialisierten IR-Kalt-Ketten über Straße (WP1-WP7) und Wiese (WP8-WP16): Detektionsleistung (oben) und Modellierungsfehler (unten).

**Tabelle 10:** Ergebnisse für spezialisierte IR-Kalt-Ketten (Threshold = 0,5, IOU = 0,4, Class = Person)

<i>Chain</i>	<i>Date</i>	<i>AP</i>	<i>F1</i>	<i>F2</i>	<i>F0.5</i>	<i>GT</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>Prec.</i>	<i>Recall</i>
<i>ch_ir-cold</i>	2013-09-05 [16:57:18]	0,28	0,44	0,33	0,66	330	94	1	236	0,99	0,28
	2014-02-27 [11:13:27]	0,96	0,95	0,96	0,94	193	186	14	7	0,93	0,96
	2014-02-27 [17:35:46]	1,00	0,95	0,98	0,92	248	248	28	0	0,90	1,00
	2014-02-27 [18:11:08]	0,96	0,94	0,96	0,92	195	189	18	6	0,91	0,97
	2014-07-04 [09:03:46]	0,78	0,86	0,84	0,88	494	409	47	85	0,90	0,83
	2014-07-04 [15:48:23]	0,59	0,74	0,65	0,86	545	326	14	219	0,96	0,60
	2021-01-20 [14:08:00]	0,89	0,94	0,91	0,97	3887	3469	42	418	0,99	0,89
	<i>All-Dates [2013-2021]</i>	0,74	0,84	0,78	0,90	3267	2450	145	817	0,94	0,75
<i>ch_ir-cold-tiny</i>	2013-09-05 [16:57:18]	0,03	0,05	0,03	0,12	330	9	0	321	1,00	0,03
	2014-02-27 [11:13:27]	0,99	0,95	0,98	0,93	193	192	19	1	0,91	0,99
	2014-02-27 [17:35:46]	0,99	0,91	0,96	0,87	248	248	47	0	0,84	1,00
	2014-02-27 [18:11:08]	0,97	0,91	0,95	0,87	194	191	36	3	0,84	0,98
	2014-07-04 [09:03:46]	0,57	0,71	0,66	0,77	494	309	67	185	0,82	0,63
	2014-07-04 [15:48:23]	0,17	0,30	0,22	0,50	545	99	13	446	0,88	0,18
	2021-01-20 [14:08:00]	0,90	0,93	0,92	0,94	3887	3570	223	317	0,94	0,92
	<i>All-Dates [2013-2021]</i>	0,59	0,72	0,65	0,81	3265	1995	266	1270	0,88	0,61
<i>ch_eo-generic</i>	2014-02-27 [11:13:27]	0,94	0,93	0,94	0,92	169	161	16	8	0,91	0,95
	2021-01-20 [14:08:00]	0,79	0,88	0,84	0,93	3352	2707	76	645	0,97	0,81
	<i>All-Dates [2013-2021]</i>	0,82	0,89	0,85	0,92	2785	2322	123	463	0,95	0,83
<i>ch_ir-generic</i>	2014-02-27 [11:13:27]	0,84	0,88	0,87	0,90	193	166	17	27	0,91	0,86
	2014-02-27 [17:35:46]	0,99	0,94	0,97	0,90	248	248	33	0	0,88	1,00
	2014-02-27 [18:11:08]	0,91	0,90	0,92	0,88	194	181	29	13	0,86	0,93
	2021-01-20 [14:08:00]	0,90	0,93	0,92	0,95	3887	3513	128	374	0,96	0,90
	<i>All-Dates [2013-2021]</i>	0,78	0,86	0,82	0,90	3260	2614	220	646	0,92	0,80
<i>ch_ir-cold - ch_eo-generic</i>	2014-02-27 [11:13:27]	0,02	0,02	0,01	0,02		25	-2		0,02	0,01
	2021-01-20 [14:08:00]	0,10	0,06	0,07	0,03		762	-34		0,02	0,08
<i>ch_ir-cold - ch_ir-generic</i>	2014-02-27 [11:13:27]	<b>0,12</b>	<b>0,06</b>	<b>0,09</b>	0,04		20	-3		0,02	0,10
	2014-02-27 [17:35:46]	0,00	0,01	0,00	0,01		0	-5		0,02	0,00
	2014-02-27 [18:11:08]	0,05	<b>0,04</b>	<b>0,04</b>	<b>0,05</b>		8	-11		0,05	0,04
	2021-01-20 [14:08:00]	<b>-0,01</b>	0,00	<b>-0,01</b>	0,02		-44	-86		0,02	-0,01
	<i>All-Dates [2013-2021]</i>	0,02	0,01	0,01	0,01		16	-10		0,02	0,01
<i>ch_ir-cold-tiny - ch_ir-generic-tiny</i>	2014-02-27 [11:13:27]	<b>0,12</b>	<b>0,08</b>	<b>0,09</b>	<b>0,07</b>		20	-12		0,06	0,10
	2014-02-27 [17:35:46]	0,00	0,00	0,00	0,00		0	-2		0,01	0,00
	2014-02-27 [18:11:08]	0,03	<b>0,06</b>	0,03	<b>0,07</b>		2	-24		0,08	0,02
	2021-01-20 [14:08:00]	0,00	0,00	0,00	<b>-0,01</b>		28	45		-0,01	0,01

### 9.2.6 Schlussfolgerungen für Modellierung und Einsatz spezialisierter Ketten

In Abschnitt 9.2 fanden Untersuchungen zur Grundannahme einer Anpassungsfähigkeit von Ketten statt. Er diente zur Klärung der Zielsetzung b) aus Abschnitt 8.1, ob sich durch spezialisierte Ketten ein Mehrwert im jeweils angedachten Einsatzraum ergibt:

- *Innerhalb des Einsatzraums* konnte für alle vorgestellten Ketten eine *Verbesserung* der Ergebnisse durch eine Anpassung an den jeweiligen Einsatzraum festgestellt werden.
- *Außerhalb des Einsatzraums* geht diese erwünschte Steigerung der Kettenleistung jedoch in der Regel mit einer *Degeneration* der Kettenleistung einher.
- Ein gezielter Einsatz spezialisierter Ketten, beispielsweise durch eine *modellbasierte Vorhersage der Kettenleistung*, ist daher zwingend *erforderlich*.

Für die eingesetzten Ketten wurde daher die Modellierung der Kettenleistung mit BNs näher erläutert und die Auswertung der Modelle während der Testflüge wurde mit der tatsächlichen Kettenleistung verglichen:

- Da *generische Ketten* mit großen Datensets hoher Variabilität trainiert wurden, konnte nachgewiesen werden, dass nicht nur die Kettenleistung ganzjährig betrachtet am besten ist, sondern auch die Vorhersagegenauigkeit der Modelle mittels BNs durchgängig „ohne große Sprünge“ gelang. Sie eignen sich also gut als *Rückfallketten* im Sinne des SPMS-Ansatzes.
- Innerhalb des Einsatzraums gelingt die Vorhersage der Kettenleistung auch für *spezialisierte Ketten* (z.B. IR-Kalt-Ketten) präzise. Darüber hinaus muss eine Abwägung bei der Modellierung zwischen Über- und Unterschätzung der Leistung erfolgen, da die Leistung spezialisierter Ketten außerhalb des Einsatzraumes unterschiedlich stark degeneriert<sup>67</sup>.

Modellierungsfehler können dazu führen, dass nicht die „besten Ketten“ ausgewählt werden. Hierbei ist es wichtig, auch die Modellierungsfehler der „*Gemeinschaft aller spezialisierten Ketten*“ zu berücksichtigen, da aus dem Vergleich aller Ketten die besten Ketten ausgewählt werden.

Falls eine Kette ausgewählt wird, die ebenfalls eine gute oder sehr gute Leistung erzielt, so haben Modellierungsfehler nur geringe Auswirkungen auf die Leistung des Gesamtsystems. Für die Anwendung des SPMS-Konzepts lässt sich daraus schließen, dass eine *Normierung des Modellierungsfehlers* auf den jeweils *maximalen Nachbardetektionswert* sinnvoll ist.

Etwas überraschend ergibt sich aus den Testreihen auch, dass kleinere CNNs nicht nur Vorteile hinsichtlich der Laufzeit aufweisen:

- Im Vergleich zu größeren CNNs war ihre Erkennungsleistung in einigen Eckfällen sogar besser. Dieser Sachverhalt wird in den ortsbezogenen Verläufen und den Leistungstabellen der Corner-Cases für EO-Dämmerung- und IR-Kalt-Ketten deutlich.

---

<sup>67</sup> u.a. aufgrund der gezielten Filterung der Trainingsdaten.

- Aufgrund der verringerten Anzahl von Knoten und Schichten ist einerseits innerhalb Einsatzraumes (und damit der Trainingsmenge) eine gezielte Anpassung möglich, andererseits ist außerhalb dafür mit einer noch stärkeren Degeneration der Leistung zu rechnen.
- Daher erscheint es sinnvoll, kleinere CNNs gezielter einzusetzen als größere CNNs.

### 9.3 Mehrwert einer SPMS-Umsetzung unter realistischen Bedingungen

Nachdem einerseits die Grundannahme einer gezielten Adaption von Ketten und die Modellierbarkeit der Kettenleistung (Abschnitt 9.2) sowie andererseits systemische Anforderungen und das Fähigkeitenkonzept (Abschnitt 7.3) untersucht worden sind, wird in diesem Abschnitt der Mehrwert des SPMS-Konzeptes im Zuge des Beispielszenarios ausgewertet.

Der Mehrwert kann hierbei eine gesteigerte Leistungsfähigkeit einer automatisierten Sensordatenauswertung unter schwierigen Umweltbedingungen oder eine prinzipielle Einsetzbarkeit auch bei Fehlern bzw. Ausfällen von Teilsystem oder Sensoren sein. Hierzu werden die folgenden Betriebszustände näher untersucht:

- *Nominaler* Betrieb: Uneingeschränkt und mit beliebigen Ressourcen
- *Fail-Operational* Betrieb: nur ein Sensor verfügbar und mit beliebigen Ressourcen
- Betrieb bei *Ressourcenknappheit*

In allen Betriebszuständen wurde das vollständige Kettensetup aus generischen EO- und IR-Ketten sowie den spezialisierten Ketten (EO-Dämmerung, EO-Schnee, IR-Gras, IR-Kalt) verwendet. Neben mittelgroßen CNNs (YOLOv4-CSP) kamen auch kleinere, effizientere Varianten zum Einsatz (YOLOv4-tiny).

Zur Vorhersage der Kettenleistung verfügt jede Kette über ein angepasstes Bayessches Netz. Der Ressourcenverbrauch wurde der Referenzimplementierung [BoWL20] entnommen.

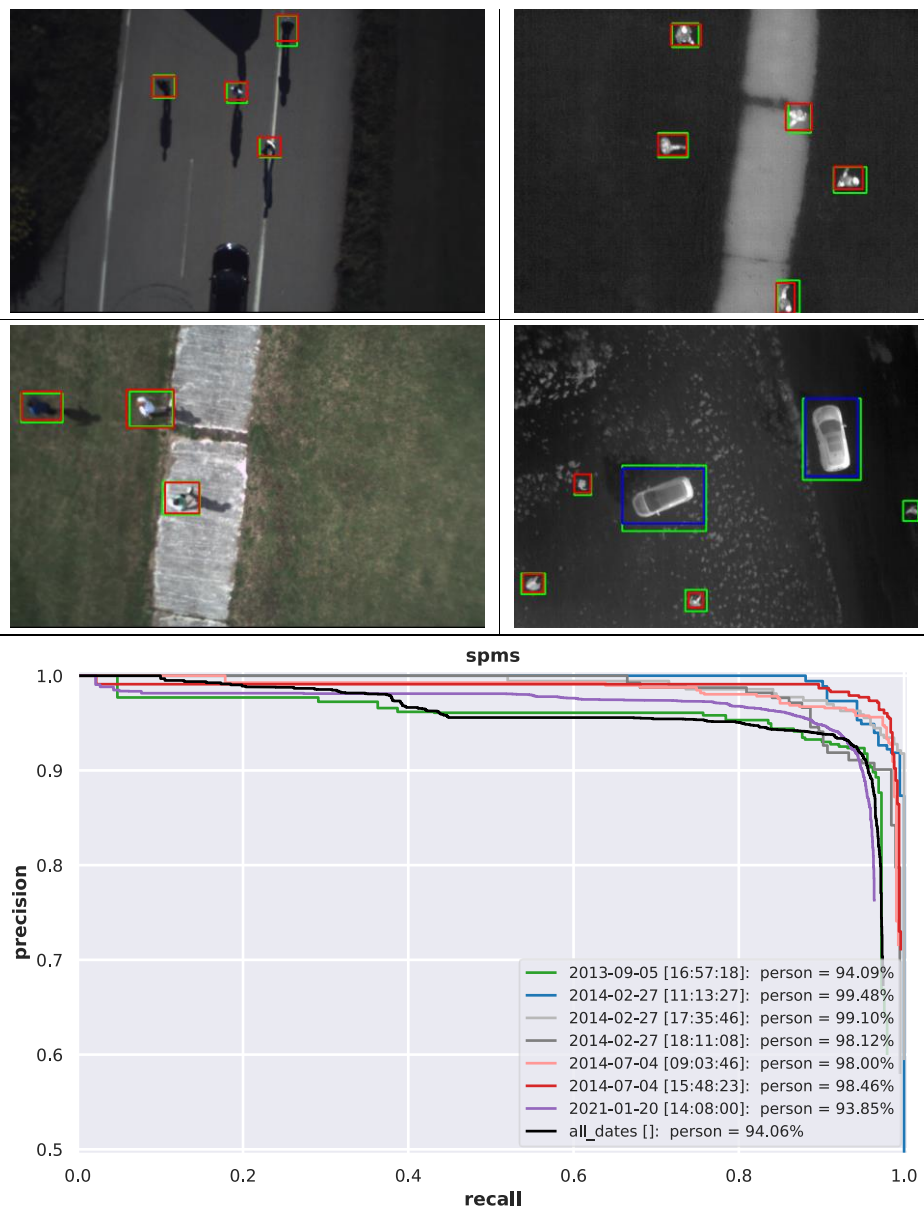
#### 9.3.1 Nominaler Betrieb

Durch Auswertung und Vergleich der Leistungsmodelle werden unterschiedliche Rangfolgen der Ketten während des Fluges ermöglicht. Eine ideale Rangfolgebestimmung der Ketten wäre mit einem Einsatz der jeweils tatsächlich besten Kette verbunden. Jahres- und Tageszeit übergreifend sowie in Abhängigkeit des Hinter- bzw. Untergrundes müsste das SPMS derart zwischen Ketten umschalten, dass immer die maximale Leistung aller Ketten erzielt wird. Folglich wurde der SPMS-Fehler als Differenz zwischen der tatsächlich besten Kette und der vom SPMS ausgewählten, voraussichtlich besten Kette definiert.

Im Leistungsverlauf des nominalen Betriebs (Abb. 76), ist hierbei schwarz die vom SPMS ausgewählte Kette dargestellt:



- Der SPMS-Verlauf ist immer sehr nahe oder gleich der tatsächlich besten Kette. Die Modellierung der Kettenleistung mittels BNs ermöglicht folglich eine sehr gute Abschätzung der jeweiligen Ketteneinsatzräume.

- Sowohl unterschiedliche Sensorarten als auch unterschiedlich trainierte CNNs werden bestmöglich eingesetzt.
- Modellierungsfehler der spezialisierten Ketten haben außerhalb ihrer jeweiligen Einsatzräume im Zusammenhang mit dem Gesamtsystem aus allen Ketten keine signifikante Auswirkung. Voraussetzung hierfür ist eine Unterschätzung der Kettenleistung außerhalb der Einsatzraume und die Existenz von alternativen Ketten, die eine deutlich höhere Leistung aufweisen.
- Durch das kontextabhängige Umschalten zwischen Ketten wird sowohl über alle Flugversuche hinweg als auch für fast jeden Flugversuch eine sehr gute Kettenleistung erzielt (siehe Tabelle 11).



**Abb. 75:** Nominaler SPMS-Betrieb: Detektionsergebnisse (oben: 2013-09-05, 2014-02-27 [17:35:46], 2014-07-04 [15:48:23], 2021-01-20) und Precision-Recall-Kurven mit AP (unten).





**Abb. 76:** Leistungsverläufe des SPMS im nominalen Betrieb über Straße (WP1-WP7) und Wiese (WP8-WP16): Detektionsleistung (oben) und Modellierungsfehler (unten).



**Tabelle 11:** Ergebnisse für generische Ketten (Threshold = 0,5, IOU = 0,4, Class = Person) mit folgendem Bewertungsschema:

unzureichend = rot [0,0 ; 0,4[ ... kritisch = orange [0,4 ; 0,7[ ... ausreichend = grau [0,7 ; 0,8[ ... gut = hell-grün [0,8 ; 0,9[ ... sehr gut = dunkel-grün [0,9 ; 1.0]

<i>Chain</i>	<i>Date</i>	<i>AP</i>	<i>F1</i>	<i>F2</i>	<i>F0.5</i>	<i>GT</i>	<i>TP</i>	<i>FP</i>	<i>FN</i>	<i>Prec.</i>	<i>Recall</i>
<i>ch_eo-generic</i>	2013-09-05 [16:57:18]	0,85	0,90	0,89	0,92	292	257	19	35	0,93	0,88
	2014-02-27 [11:13:27]	0,94	0,93	0,94	0,92	169	161	16	8	0,91	0,95
	2014-02-27 [17:35:46]	0,66	0,76	0,71	0,81	202	138	25	64	0,85	0,68
	2014-02-27 [18:11:08]	0,01	0,02	0,01	0,05	95	1	0	94	1,00	0,01
	2014-07-04 [09:03:46]	0,96	0,96	0,97	0,96	426	415	21	11	0,95	0,97
	2014-07-04 [15:48:23]	0,96	0,97	0,97	0,97	494	479	16	15	0,97	0,97
	2021-01-20 [14:08:00]	0,79	0,88	0,84	0,93	3352	2707	76	645	0,97	0,81
	<i>All-Dates [2013-2021]</i>	0,82	0,89	0,85	0,92	2785	2322	123	463	0,95	0,83
<i>ch_ir-generic</i>	2013-09-05 [16:57:18]	0,58	0,73	0,63	0,86	323	187	4	136	0,98	0,58
	2014-02-27 [11:13:27]	0,84	0,88	0,87	0,90	193	166	17	27	0,91	0,86
	2014-02-27 [17:35:46]	0,99	0,94	0,97	0,90	248	248	33	0	0,88	1,00
	2014-02-27 [18:11:08]	0,91	0,90	0,92	0,88	194	181	29	13	0,86	0,93
	2014-07-04 [09:03:46]	0,67	0,78	0,75	0,81	494	362	70	132	0,84	0,73
	2014-07-04 [15:48:23]	0,71	0,81	0,75	0,89	545	391	25	154	0,94	0,72
	2021-01-20 [14:08:00]	0,90	0,93	0,92	0,95	3887	3513	128	374	0,96	0,90
	<i>All-Dates [2013-2021]</i>	0,78	0,86	0,82	0,90	3260	2614	220	646	0,92	0,80
<i>ch_eo-generic-tiny</i>	<i>All-Dates [2013-2021]</i>	0,81	0,87	0,85	0,88	2785	2339	281	446	0,89	0,84
<i>ch_ir-generic-tiny</i>	<i>All-Dates [2013-2021]</i>	0,79	0,84	0,82	0,87	3266	2648	354	618	0,88	0,81
<i>SPMS (nominal)</i>	2013-09-05 [16:57:18]	0,85	0,90	0,89	0,92	292	257	19	35	0,93	0,88
	2014-02-27 [11:13:27]	0,99	0,95	0,98	0,93	193	192	19	1	0,91	0,99
	2014-02-27 [17:35:46]	0,99	0,91	0,96	0,87	246	246	47	0	0,84	1,00
	2014-02-27 [18:11:08]	0,97	0,91	0,95	0,87	194	191	36	3	0,84	0,98
	2014-07-04 [09:03:46]	0,96	0,96	0,97	0,96	426	415	21	11	0,95	0,97
	2014-07-04 [15:48:23]	0,96	0,97	0,97	0,97	494	479	16	15	0,97	0,97
	2021-01-20 [14:08:00]	0,90	0,93	0,92	0,94	3886	3567	222	319	0,94	0,92
	<i>All-Dates [2013-2021]</i>	0,90	0,93	0,93	0,93	3084	2881	217	203	0,93	0,93

### 9.3.2 Fail-Operational Betrieb

Unter erschwerten Einsatzbedingungen ist neben witterungsbedingten Störungen<sup>68</sup> mit Staub, Schmutz, Verschleiß (Objektive) oder Beschuss zu rechnen. Eine Beeinträchtigung der Sensorqualität aber auch ein Totalausfall von Sensoren können also nicht ausgeschlossen werden.

Wie in Abb. 77 dargestellt, kann durch den Einsatz SPMS selbst bei Totalausfall eines Sensors ein Fail-Operational-Betrieb mit akzeptabler Leistung ( $F2 > 60\%$ ) gewährleistet werden. Hierfür ausschlaggebend ist der gezielte, modellbasierte Einsatz von auf Edge- und Corner-Cases adaptierter Ketten:

- EO-Dämmerung-Kette (Abschnitt 9.2.4)
- IR-Gras-Kette (Abschnitt 9.2.4)

Sie erweitern den Einsatzraum der jeweiligen Sensoren gerade unter schwierigen Bedingungen (EO: bei Restlicht, IR: über Vegetation an heißen Tagen).

Folglich könnte ein Einsatz des SPMS-Systems gegebenenfalls einen Abbruch der Mission vermeiden und die Erreichung der Missionsziele weiterhin ermöglichen.

---

<sup>68</sup> U.a. Regen, Nebel, Vereisung.





Abb. 77: Leistungsverläufe des SPMS bei Totalausfall des LWIR-Sensors (oben) bzw. bei Totalausfall des EO-Sensors (unten).



### 9.3.3 Betrieb bei Ressourcenknappheit

Die auf kleineren UAVs begrenzten Ressourcen müssen nicht nur auf verschiedene Detektionsaufgaben, sondern auch für die Planung des Sensoreinsatzes und Flugpfades sowie für die Situationsanalyse und das Missionsmanagement aufgeteilt werden. Daher stehen je nach Situation und Missionskontext nicht unbegrenzt Ressourcen für die Auswertung von Sensordaten zur Verfügung.



Im SPMS sind zur Skalierung und Optimierung der verfügbaren Ressourcen verschiedene gewichtete Winner-Determination-Funktionen vorgesehen. Zusätzlich können Anspruchsniveaus wie ein maximaler Ressourcenverbrauch und eine Mindestleistung, die nicht unterschritten werden darf, festgelegt werden (Abschnitt 7.2).

Die Testreihen wurden mit einer an den Ressourcenverbrauch angepassten Winner-Determination-Funktion (Abb. 44) wiederholt. Aus den Leistungs- und Fehlerverläufen (Abb. 78, Abb. 79) können im Vergleich zum nominalen Betrieb (Abschnitt 9.3.1) die folgenden Schlussfolgerungen gezogen werden:

- Die Rangfolge der Ketten ändert sich zugunsten effizienter Ketten.
- In der Rangfolge können weiterhin Standardketten vorkommen, falls der vorhergesagte Leistungsunterschied zwischen normalen und effizienten Ketten zu groß ist. Ein Beispiel hierfür ist der Einsatz der normalen IR-Gras-Kette im Flugversuch 2014-07-04 [15:48:23] (Abb. 79).
- Spezialisierte, effiziente Ketten bieten in manchen Fällen eine Leistung, die mit normalen Ketten vergleichbar ist. Unter besonderen Umständen können kleine Netzwerke sogar präziser angepasst werden und bessere Ergebnisse liefern, beispielsweise bei Restlicht.
- Insgesamt ergibt sich im Vergleich zum nominalen Betrieb eine etwas verringerte Leistung. Wenn die Leistungsdifferenz zwischen Standard- und effizienten Ketten zu groß ist, keine guten effizienten Alternativen vorhanden sind und zusätzlich Modellierungsungenauigkeiten auftreten, können auch größere Leistungseinbußen entstehen. Dies veranschaulicht sich im Flugversuch 2014-07-04 [15:48:23] (Abb. 78).



**Abb. 78:** Leistungsverläufe des SPMS im ausbalancierten Betrieb über Straße (WP1-WP7) und Wiese (WP8-WP16): Detektionsleistung (oben) und Modellierungsfehler (unten).



**Abb. 79:** Leistungsverläufe des SPMS im ausbalancierten Betrieb bei Totalausfall des LWIR-Sensors (oben) bzw. bei Totalausfall des EO-Sensors (unten).





## 10. Zusammenfassung

Thema dieser Arbeit war die Konzeption und prototypische Implementierung eines Sensor- und Perzeptionsmanagementsystems (SPMS) für unbemannte fliegende Plattformen.

Der erfolgreiche Einsatz unbemannter Luftfahrzeuge (UAVs) ist bei Überwachungs- und Aufklärungsmissionen eng mit der Qualität der erfassten Sensordaten und deren zuverlässiger Auswertung verbunden. Sowohl die Sensordaten als auch ihre Auswertung werden maßgeblich von den herrschenden Umweltbedingungen und dem aktuellen Zustand der Sensor- und UAV-Plattform beeinflusst. Je nach Kontext und Sensorkonfiguration können die negativen Auswirkungen unterschiedlich stark auftreten und u.U. den Einsatz oder das Erreichen der Missionsziele gefährden.

Selbst bei ungünstigen Umgebungs- und Plattformzuständen können nach dem Flug häufig Sensor-Algorithm-Konfigurationen (Ketten) gefunden werden, die doch eine ausreichend gute Leistung hätten erzielen können. Für den operationellen Einsatz von UAS ist es jedoch erforderlich, diesen händisch durchgeführten, manuellen Prozess zu automatisieren.

Die Grundannahme des SPMS-Konzepts besteht daher darin, dass Ketten aus Sensoren und Algorithmen situativ und umweltbedingt optimal angepasst werden. Dazu werden verschiedene Kettenmodelle für unterschiedliche Umweltkonstellationen im Voraus trainiert, modelliert und während des Fluges unter Berücksichtigung der verfügbaren Rechenkapazitäten gezielt ausgewählt.

Zur Evaluierung des Konzepts und der eingesetzten Methoden wurden Flugversuche geplant, durchgeführt und ausgewertet, um den Mehrwert des SPMS im Sinne einer Steigerung der Detektionsleistung unter realistischen Umweltbedingungen zu belegen.

### 10.1 Beantwortung der Forschungsfragen

#### 10.1.1 Konzeptionelle Ausarbeitung

➤ *Wie könnte ein ganzheitliches Systemkonzept aussehen?*

Um den operationellen und systemischen Anforderungen sowie dem hohen Grad der Automation künftiger autonomer Systeme gerecht zu werden, wurde ein ganzheitliches, innovatives Systemkonzept aufgestellt [RuSt12] und erweitert [HSRS12, RuHS18]:

Das Zusammenspiel zwischen Missionsmanagementsystem (MMS) bzw. Operateur und der Wahrnehmungs- und Sensorebene wird durch einen mehrschichtigen Ansatz ermöglicht, indem intelligente Subsysteme einerseits die Aufgaben der Flugführung (FMS) und andererseits den Sensoreinsatz und dessen Auswertung (SPMS) automatisieren. Das Missionsmanagementsystem (MMS) auf höchster Ebene überwacht dabei die Fähigkeiten der Subsysteme und zerlegt Aufträge in Aufgaben für das FMS („*Navigation Tasks*“) und das SPMS („*Perception Tasks*“).

Das *SPMS* kombiniert das Perzeptionsmanagementsystem (PMS, mittlere Ebene) mit dem Sensormanagementsystem (SMS, unterste Ebene):

- Das *PMS* abstrahiert Wahrnehmungsfähigkeiten, empfängt Aufträge vom *MMS*, überwacht und steuert das *SMS* und generiert Verbesserungsvorschläge für das *FMS*. Hierfür ist das Zusammenwirken mehrerer Komponenten nötig: *Perception Solver (PS)*, *Processing Coordinator*, *Resource Monitor* und *Result Validator*.
- Das *SMS* erstellt und prüft Sensoreinsatzpläne zur Konfiguration, Ausrichtung, Auswahl und Überwachung der Sensoren während des Fluges.

Zum Überwachen und Einsetzen der Fähigkeiten wird Wissen über alternative Ketten modelliert und während des Fluges ausgewertet. Hierdurch wird die Adaption der Ketten an aktuelle Umweltgegebenheiten und deren Anpassung an zur Verfügung stehende Ressourcen ermöglicht.

### 10.1.2 Methodenauswahl und Umsetzung

➤ *Mit welchen Methoden wäre eine prototypische Umsetzung möglich?*

Zur Umsetzung der *SPMS*-Architektur wurde ein verteiltes, marktbasierendes Kettenmanagement und eine multikriterielle Kettenbewertung zur Rangfolgebestimmung implementiert [RuSt13a].

Wahrnehmungsaufträge sowie die Abfrage aller verfügbaren Fähigkeiten werden vom *SPMS* in eine Sequenz von *Auktionen* mit Ablaufzeiten umgewandelt. Jede Auktion umfasst eine Aufgabenbeschreibung (Kettentyp, Sensortyp und Einsatzort), Task-ID, die Vorgabe von Prioritäten und die Verknüpfung mit Wegpunkten. Sämtliche Ketten abonnieren die Auktionen und antworten bei Übereinstimmung mit der eigenen Fähigkeit mit einem Angebot. Diese *Perception-Bids* werden von den Ketten durch Auswertung der Leistungs- und Ressourcenmodelle berechnet und veröffentlicht. Entsprechend den Missionsbedürfnissen kommen unterschiedliche Bewertungen (Winner-Determination-Functions) zum Einsatz, um aus den Angeboten eine Rangfolge der Ketten zu erstellen. Aus der Rangfolge und der Aufgabenpriorität werden die Laufzeitparameter (Aktivität, Prozess-PID, Priorität) von Ketten erstellt oder angepasst. Zum gezielten Stoppen, Starten und Priorisieren von Ketten werden neben Laufzeitparametern auch die Task-IDs, Ketten-IDs sowie die aktuell verfügbaren Ressourcen vom PC in einer Datenbank gespeichert (*Bookkeeping*). Werden relevante Eingangsparameter oder Alarm-Schranken bezüglich Umgebungsparametern, Sensor- bzw. Plattformzuständen oder Ressourcen überschritten, so wird automatisch eine Neubewertung der Ketten durchgeführt.

Zur Leistungsbestimmung wurden in [RSHS13] Ketteneinsatzmodelle auf Basis Bayesscher Netze für klassische, ressourcensparende Bildverarbeitungsketten eingeführt, in das *SPMS* integriert und während des Fluges zur Vorhersage der Kettenleistung ausgewertet.

Zur Vorhersage der Kettenleistung verfügt jede Kette über ein kettenspezifisches Bayessches Netz. Diese Kettenmodelle sind eine dezentrale, graphische Wissensrepräsentation der Ketteneinsatzräume über die Tauglichkeit von Sensoren sowie der Adaptionmöglichkeiten der Algorithmen. Die Art der Kettenmodellierung wurde nach ausführlicher Literaturrecherche gewählt, da graphische, probabilistische Methoden im Vergleich zu anderen Methoden eine

Modellierung unsicherer Umweltzustände und vager Hypothesen ermöglichen und kleine, kettenspezifische Bayessche Netze für den Menschen nachvollziehbar sind.

Bereits während der Konzepterstellung wurden systemische Anforderungen wie Erklärbarkeit und Transparenz sowie Erweiterbarkeit und Robustheit bei Ausfall einzelner Ketten bzw. Sensoren explizit berücksichtigt. Zum Nachweis wurden separate Testdurchläufe im Rahmen einer Validierung der SPMS-Realisierung erfolgreich bestanden.

### 10.1.3 Realisierung und Erprobung im Flugversuch

- *Kann mit Hilfe des Systemkonzepts ein Sensoreinsatz und dessen Auswertung so weit automatisiert werden, dass eine dem menschlichen ähnliche oder bessere Erkennungsleistung auch unter variierenden und erschwerten Umwelt- und Plattformzuständen möglich ist?*

In [RSHS13] wurden zunächst klassische, ressourcensparende Bildverarbeitungsroutinen eingesetzt. Zusätzlich wurden in [RuSt23] state-of-the-art CNN-basierte Ketten untersucht und ein neuer Flugversuchsträger mit verbesserter Sensorik eingesetzt. Aufgrund der dezentralen SPMS-Architektur und der gewählten Modellierungsmethode war eine einfache Integration neuer Ketten durch Anpassung vorhandener Modelltemplates möglich.

Zur Evaluierung im Rahmen eines Anwendungsszenarios (Verkehrsunfallszenario) wurde ein Kettensetup aus generischen EO- und IR-Ketten, spezialisierten Ketten (EO-Dämmerungs-Ketten, EO-Schnee-Ketten, IR-Gras-Ketten und IR-Kalt-Ketten) und effizienten Ketten (kleine CNN-Varianten) eingesetzt.

Zunächst wurde die Grundannahme einer Anpassungsmöglichkeit von Ketten untersucht. Anhand von Sensordaten aus realen Flugversuchen konnte nachgewiesen werden, dass sich durch spezialisierte Ketten ein Mehrwert im jeweils angedachten Einsatzraum ergibt:

- *Innerhalb des Einsatzraums* konnte durch gezieltes Training für alle vorgestellten Ketten eine teils deutliche *Verbesserung* der Ergebnisse festgestellt werden.
- *Außerhalb des Einsatzraums* geht dies jedoch mit einer *Degeneration* der Kettenleistung einher.
- Ein gezielter Einsatz spezialisierter Ketten, beispielsweise durch eine *modellbasierte Vorhersage der Kettenleistung*, ist daher *zwingend erforderlich*.

Der Gesamtmehrwert wurde durch Auswertung von Referenzflugversuchen in Form mehrerer Leistungsmetriken bestimmt, tabellarisch zusammengefasst und bewertet.

#### **Zusammengefasst lassen sich die Ergebnisse wie folgt darstellen:**

Durch den Einsatz des SPMS wurde eine automatisierte, ganztägige und ganzjährige Sensordatenauswertung unter schwierigen Umweltbedingungen im nominalen Betrieb (Abschnitt 9.3.1) ermöglicht:

- Über alle Flugversuche gemittelt („*All-Dates*“ in Tabelle 12) wurde mit dem SPMS eine Detektionsleistung von 93% erzielt.

- Im Gegensatz zu generischen EO- und IR-Ketten sowie spezialisierten Ketten ist dabei nur eine minimale Abweichung für einzelne Flugversuche erkennbar. Selbst die „schlechteste Flugversuchsleistung“ lag bei Nutzung des SPMS mit 89% (F2-Score) fast noch im sehr guten Zuverlässigkeitsbereich.

**Tabelle 12:** Zusammenfassung der SPMS-Ergebnisse und Vergleich mit generischen EO- und IR-Ketten.

<i>Chain</i>	<i>Date</i>	<i>F1</i>	<i>F2</i>	<i>F0.5</i>
<i>ch_eo-generic</i>	2013-09-05 [16:57:18]	0,90	0,89	0,92
	2014-02-27 [11:13:27]	0,93	0,94	0,92
	2014-02-27 [17:35:46]	<b>0,76</b>	<b>0,71</b>	0,81
	2014-02-27 [18:11:08]	<b>0,02</b>	<b>0,01</b>	<b>0,05</b>
	2014-07-04 [09:03:46]	0,96	0,97	0,96
	2014-07-04 [15:48:23]	0,97	0,97	0,97
	2021-01-20 [14:08:00]	0,88	0,84	0,93
	<i>All-Dates [2013-2021]</i>	<i>0,89</i>	<i>0,85</i>	<i>0,92</i>
	<i>ch_ir-generic</i>	2013-09-05 [16:57:18]	<b>0,73</b>	<b>0,63</b>
2014-02-27 [11:13:27]		0,88	0,87	0,90
2014-02-27 [17:35:46]		0,94	0,97	0,90
2014-02-27 [18:11:08]		0,90	0,92	0,88
2014-07-04 [09:03:46]		<b>0,78</b>	<b>0,75</b>	0,81
2014-07-04 [15:48:23]		0,81	<b>0,75</b>	0,89
2021-01-20 [14:08:00]		0,93	0,92	0,95
<i>All-Dates [2013-2021]</i>		<i>0,86</i>	<i>0,82</i>	<i>0,90</i>
<i>SPMS (nominal)</i>		2013-09-05 [16:57:18]	0,90	<b>0,89</b>
	2014-02-27 [11:13:27]	0,95	0,98	0,93
	2014-02-27 [17:35:46]	0,91	0,96	0,87
	2014-02-27 [18:11:08]	0,91	0,95	0,87
	2014-07-04 [09:03:46]	0,96	0,97	0,96
	2014-07-04 [15:48:23]	0,97	0,97	0,97
	2021-01-20 [14:08:00]	0,93	0,92	0,94
	<i>All-Dates [2013-2021]</i>	<i>0,93</i>	<i>0,93</i>	<i>0,93</i>

Neben dem nominalen Betrieb, konnte mit dem SPMS ein Fail-Operational-Betrieb (Abschnitt 9.3.2) zur prinzipiellen Einsatzbarkeit bei Fehlern bzw. Ausfällen von Teilsystemen oder Sensoren sowie ein ressourcenoptimierter Betrieb (Abschnitt 9.3.3) ermöglicht und nachgewiesen werden.

Das SPMS-Konzept eignet sich daher besonders für zukünftige autonome Systeme, die einen hohen Grad an Automation erfordern und eine zuverlässige Wahrnehmung unter sich ändernden Umweltbedingungen benötigen.

## 10.2 Ausblick

Im Rahmen dieser Arbeit stand die prototypische Umsetzung und der Nachweis der Realisierbarkeit im Fokus. Es wurden die wichtigsten Kernelemente des SPMS umgesetzt und getestet. Aus den im Konzept vorgesehenen, aber nicht umgesetzten Komponenten ergeben sich neue Themen und Fragen, die sukzessive in das bestehende SPMS integriert werden könnten:

- Eine detaillierte Untersuchung des *Result-Validators* (Late-Fusion) könnte dazu beitragen, die Ergebnisse plausibler zu machen, die False-Positive-Rate zu reduzieren und die Lokalisierungsgenauigkeit zu verbessern.
- Um getarnte Objekte zu erkennen, was als einer der schwierigsten Fälle angesehen wird, oder um Gase und Flüssigkeiten (beispielsweise bei Unfällen) zu lokalisieren, sind neue hochspezialisierte Ketten erforderlich. In solchen Szenarien wäre der Einsatz von Multi- oder Hyperspektralsensoren denkbar. Durch den Einsatz dieser speziellen Sensoren soll die Detektions- und Lokalisierungsgenauigkeit weiter verbessert oder eine Detektion erst ermöglicht werden.
- Neben neuen Sensoren könnten auch weitere Ketten mit unterschiedlichen Auswertelgorithmen untersucht werden. Insbesondere für größere UAVs werden immer leistungsstärkere Missionsrechner zur Verfügung stehen. In diesem Kontext könnten sowohl CNNs als auch Vision-Transformer als alternative Ansätze in Betracht gezogen werden.
- Für den Einsatz des SPMS fehlt bisher eine integrierte Sensorpfadplanung. Der optimierte, gezielte Sensoreinsatz könnte zu einer deutlichen Verbesserung der Beobachtungsfähigkeiten sowie zu einer optimalen Nutzung der Missionssensoren führen und so den Mehrwert des SPMS deutlich steigern.
- Die Möglichkeiten einer Modellierung der Ketteneinsatzräume durch BNs wurden bisher noch nicht vollständig ausgeschöpft. Theoretisch könnte die Richtung des Schlussfolgerns umgekehrt werden, um die Generierung von Verbesserungsvorschlägen zu ermöglichen. Praktisch wurde dies jedoch im Rahmen des SPMS bisher noch nicht umgesetzt.

Erweiterbarkeit, Skalierbarkeit sowie Verständlichkeit waren Grundanforderungen für das SPMS-Konzept. Große Teile dieser Arbeit, wie die verteilte Architektur, die Rangfolgebestimmung sowie die Ketten-Modellierungen lassen sich im Rahmen künftiger Forschungsarbeiten weiterverwenden.



## Eigene Veröffentlichungen

[RuSt12] RUSS, MARTIN ; STÜTZ, PETER: Airborne sensor and perception management: A conceptual approach for surveillance UAS. In: Information Fusion (15th FUSION), IEEE Conference, 2012

[HSRS12] HELLERT, C ; SMIRNOV, D ; RUSS, M ; STÜTZ, P: A High Level Active Perception Concept for UAV Mission Scenarios. In: Deutscher Luft- und Raumfahrtkongress, DLRK, 2012

[RuSt13] RUSS, MARTIN ; STÜTZ, PETER: Application of a Probabilistic Market-based Approach in UAV Sensor & Perception Management. In: Information Fusion (16th FUSION), IEEE Conference, 2013

[RSHS13] RUSS, MARTIN ; SCHMITT, MARC ; HELLERT, CHRISTIAN ; STÜTZ, PETER: Airborne sensor and perception management: Experiments and Results for surveillance UAS. In: AIAA Infotech@Aerospace Conference. Reston, Virginia, American Institute of Aeronautics and Astronautics, 2013

[RuHS18] RUSS, MARTIN ; HELLERT, CHRISTIAN ; STÜTZ, PETER: Sensor & Perception Management for UAVs: Foundation and Application. In: Workshop on AI and Cognitive Technologies for Radar, Comms and EW. Brüssel: EDA, 2018

[RuSt23] RUSS, MARTIN ; STÜTZ, PETER: Airborne Sensor and Perception Management: Context-Based Selection of Specialized CNNs to Ensure Reliable and Trustworthy Object Detection. In: Modelling and Simulation for Autonomous Systems. Springer International Publishing, 2023

## Weitere wissenschaftliche Beiträge mit Beteiligung

[CLHR14, HRSS12]: Auftragsbasierte Führung und Sensor-Pfad-Planung von UAVs als mobiler Sensorknoten in einem Multi-Sensornetzwerk (MEDUSA: „Multi Sensor Data Fusion Grid for Urban Situational Awareness“, EDA-Projekt).

[RVSO12]: Integration und Erprobung eines kleinen, und leichten LIDAR-Sensors sowie Evaluierung einer automatisierten Detektion von Fahrzeugen.

[DFRS19]: Anpassung, Transfer und Einsatz des SPMS-Konzepts zur automatisierten Wolkenerkennung mit EO- und LWIR-Sensoren.

[KrRS20]: Vergleich der Trainingsdatengewinnung aus realen Flugversuchen und synthetisch erzeugten Sensordaten.

[LNSH23]: Training und Augmentieren synthetischer Trainingsdaten zur Erkennung von (Gefechts-)/Fahrzeugen unter erschwerten Einsatzbedingungen u.a. Tarnung.





## Mögliches Anwendungsszenario

Als künftiges Anwendungsszenario bietet sich der Einsatz kleiner, automatisiert eingesetzter UAVs im Rahmen einer luftgestützten *Verkehrs-/Unfallüberwachung zur Unterstützung von Rettungskräften* bei Unfällen oder Katastrophen an. Für die weiteren Ausführungen sind der Anwendungsrahmen und mögliche Umwelt- bzw. Verkehrssituationen in Abb. 80 dargestellt.

Der Einsatz von UAS bei der Verkehrsüberwachung und im Zuge von Rettungseinsätzen kann einen großen Nutzen bringen, muss jedoch gerade unter erschwerten Umwelteinflüssen möglich sein [Puri05], [Vach15]. Hierzu wurden u.a. im Rahmen des vom BMBF geförderten SOGRO Projektes [Bund09] Probleme und Anforderungen bei Großeinsätzen sowie geeignete rettungstechnische Mittel und Maßnahmen untersucht. Im Rahmen von SOGRO wurden zwischen 2010 und 2018 mehrere Großübungen von Feuerwehr und Rettungskräften am Flughafen Frankfurt [Feue18] durchgeführt. Hierbei ist v.a. der Abschlussbericht der Uni-Paderborn zur nutzbringenden „Bildauswertung und Koordinierung für einen Schwarm unbemannter Flugobjekte zur videogestützten Überwachung eines Großunfalls“ [SRKK13] von Interesse und hat zur Auswahl und Detailierung des Szenarios beigetragen:

- Im Gegensatz zu bemannten Rettungshubschraubern bietet sich mit kleinen, von den Einsatzkräften selbst einsetzbaren UAVs eine kostengünstige, schnell und einfach nutzbare Alternative zur Unterstützung von Rettungskräften an.
- Neben dem Erkennen von Staus und Verkehrsunfällen (Erkennung von Fahrzeugen), könnten die Missionssensoren der UAVs genutzt werden, um automatisiert und zeitnah nach verletzten Personen zu suchen.
- Eine schnelle Hilfe durch Rettungskräfte wird häufig durch verlassene Autos und/oder Gegenständen verhindert. UAVs könnten bereits vor dem Eintreffen der Rettungskräfte zur Erkennung potenzieller Hindernisse (Staus, Trümmerteile, etc.) genutzt werden, um so optimale Routen zu den Verletzten zu berechnen.
- Kleine UAVs sind hinsichtlich ihrer Ressourcen eingeschränkt, was bei der anwendungsorientierten Ausstattung mit Missionssensoren und Rechnern zu Einschränkungen führt.
- Der Einsatz von UAVs im Katastrophenfall oder während Unfällen muss gerade unter schwierigen Witterungsverhältnissen und Situationen für die Einsatzkräfte zuverlässig möglich sein. Die erschwerten Umweltverhältnisse wirken sich dabei i.d.R. negativ auf die Qualität Sensordaten und damit auch auf deren (automatisierte) Auswertung aus.
- Der zielgerichtete Einsatz von UAVs muss zudem die Ersthelfer unterstützen und sollte sie nicht durch deren komplexe Bedienung oder mangelnde Robustheit von ihren Tätigkeiten ablenken. Dies erfordert neben einer computergestützten Flugführung auch einen automatisierten Sensoreinsatz und eine schnelle, zuverlässige Auswertung der Sensordaten.



**Abb. 80:** Missionsszenario: Verkehrsüberwachung und Koordination von Rettungskräften werden bisher noch weitgehend mit Hilfe bemannter Fluggeräte (Rettungs- bzw. Polizeihubschrauber) durchgeführt. Künftig ist jedoch auch ein unterstützender, automatisierter Einsatz (autonom) UAVs denkbar. Dies könnte zu kürzeren Reaktionszeiten, einer großflächigeren und gleichzeitigen Beobachtung mehrerer kritischer Punkte/Regionen und zu einer Reduktion der Kosten führen [Puri05], [Vach15].

Diese Möglichkeiten aber auch die Herausforderungen eines automatisierten Einsatzes (kleiner) UAVs sind die Motivation hinter dieser Arbeit. Sie bilden die Grundlage für die zu beantwortenden Forschungsfragen und stellen zugleich systemische Anforderungen (Kapitel 4), die dem Entwurf des SPMS-Konzeptes zu Grunde lagen.

## Literaturverzeichnis

- [ALHM14] AUGUGLIARO, F ; LUPASHIN, S ; HAMER, M ; MALE, C ; HEHN, M ; MUELLER, M W ; WILLMANN, J S ; GRAMAZIO, F ; U. A.: The Flight Assembled Architecture installation: Cooperative construction with flying machines. In: *Control Systems, IEEE* Bd. 34 (2014), Nr. 4 — ISBN 1066-033X VO - 34
- [Ange12] ANGELOV, PLAMEN: *Sense and Avoid in UAS: Research and Applications*, 2012 — ISBN 9781119964049
- [Aust09] AUSTIN, R: *Unmanned aircraft systems*. Bd. 54, 2009 — ISBN 9780470664797
- [Azaa07] AZAALW, FACHBEREICH BILDAUSWERTUNG: *Grundlagen Sensorarten*, 2007
- [Bak00] BAK, THOMAS: *Lecture Notes - Estimation and Sensor Information Fusion* (2000)
- [Bald14] BALDENHOFER, KURT: *Lexikon der Fernerkundung*. URL <http://www.felexikon.info/dvd.htm>. - abgerufen am 2014-09-16
- [Barb12] BARBER, DAVID: *Bayesian reasoning and machine learning* : Cambridge University Press, 2012
- [Barr07] BARRHO, JÖRG: *Sensor- und bildverarbeitungsgestützte Erkennung von Gefahrensituationen*, Universität Karlsruhe (TH), 2007
- [BeIr07] BENASKEUR, A. ; IRANDOUST, H.: *Sensor management for tactical surveillance*, 2007
- [BeKe19] BEIERLE, CHRISTOPH ; KERN-ISBERNER, GABRIELE: *Methoden wissensbasierter Systeme: Grundlagen, Algorithmen, Anwendungen* : Springer-Verlag, 2019
- [Bena02] BENASKEUR, ABDER: *Sensor Management in Command & Control* (2002), Nr. Figure 2
- [BeOb00] BEDWORTH, MARK ; O'BRIEN, JANE: The Omnibus model: a new model of data fusion? In: *IEEE Aerospace and Electronic Systems Magazine* Bd. 15 (2000), Nr. 4, S. 30–36
- [BePS06] BEYERER, JÜRGEN ; PUENTE LEÓN, FERNANDO ; SOMMER, K.-D.: *Informationsfusion in der Mess- und Sensortechnik*, 2006 — ISBN 9783866440531
- [Bich00] BICHLER, MARTIN: An experimental analysis of multi-attribute auctions. In: *Decision Support Systems* Bd. 29 (2000), Nr. 3, S. 249–268
- [BiKa05] BICHLER, MARTIN ; KALAGNANAM, JAYANT: Configurable offers and winner determination in multi-attribute auctions. In: *European Journal of Operational Research* Bd. 160 (2005), Nr. 2, S. 380–394. — *Decision Support Systems in the Internet Age*
- [BiRo07] BISANTZ, ANN ; ROTH, EMILIE: Analysis of Cognitive Work. In: *Reviews of*

- Human Factors and Ergonomics* Bd. 3 (2007), Nr. 1, S. 1–43
- [Blom10] BLOM, JOHN DAVID: *Unmanned Aerial Systems: a historical perspective*, 2010 — ISBN 1470093510
- [Bmwi21] (BMW)", "BUNDESMINISTERIUMS FÜR WIRTSCHAFT UND ENERGIE: *Erklärbare KI: Anforderungen, Anwendungsfälle und Lösungen*, 2021
- [Bonf09] BONFIM, CLEMENTE DE CASTRO: *Reliability and Safety Improving Methods for the Evaluation of Driving Environment Information*, 2009
- [Bort00] BORTOFF, SCOTT A: Path planning for UAVs. In: *American Control Conference, 2000. Proceedings of the 2000*. Bd. 1, 2000, S. 364–368
- [BoWL20] BOCHKOVSKIY, ALEXEY ; WANG, CHIEN-YAO ; LIAO, HONG-YUAN MARK: YOLOv4: Optimal Speed and Accuracy of Object Detection (2020)
- [Boyd87] BOYD, J R: *A discourse on winning and losing*. Bd. 43947, 1987
- [BPHR11] BACHRACH, ABRAHAM ; PRENTICE, SAMUEL ; HE, RUIJIE ; ROY, NICHOLAS: RANGE—Robust autonomous navigation in GPS-denied environments. In: *Journal of Field Robotics* Bd. 28, Wiley Subscription Services, Inc., A Wiley Company (2011), Nr. 5, S. 644–666
- [BPIC12] BESNERAIS, G LE ; PLINVAL, H DE ; ISRAEL, J ; CORNIC, PH ; TREIL, A ; WATANABE, Y ; PLYER, A: Perception for UAV: Vision-Based Navigation and Environment Modeling. In: *Aerospace Lab (AL)* Bd. 4 (2012), Nr. 4, S. 1–19
- [BrAL11] BROCKHAUS, RUDOLF ; ALLES, WOLFGANG ; LUCKNER, ROBERT: *Flugregelung*, 2011
- [BrSc12] BRUEGGENWIRTH, STEFAN ; SCHULTE, AXEL: COSA2 - A Cognitive System Architecture with Centralized Ontology and Specific Algorithms. In: *2012 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* : IEEE, 2012 — ISBN 978-1-4673-1714-6, S. 307–314
- [BRSV22a] BRAZDIL, PAVEL ; VAN RIJN, JAN ; SOARES, CARLOS ; VANSCHOREN, JOAQUIN: Metalearning Approaches for Algorithm Selection I (Exploiting Rankings). In: , 2022 — ISBN 978-3-030-67023-8, S. 19–37
- [BRSV22b] BRAZDIL, PAVEL ; VAN RIJN, JAN ; SOARES, CARLOS ; VANSCHOREN, JOAQUIN: Metalearning in Ensemble Methods. In: , 2022 — ISBN 978-3-030-67023-8, S. 189–200
- [BSDL13] BLASCH, E ; STEINBERG, A ; DAS, S ; LLINAS, J ; CHONG, C ; KESSLER, O ; WALTZ, E ; WHITE, F: Revisiting the JDL model for information exploitation. In: *Proceedings of the 16th International Conference on Information Fusion, FUSION 2013* (2013), S. 129–136 — ISBN 9786058631113 (ISBN)
- [Bund09] BUNDESMINISTERIUM FÜR BILDUNG UND FORSCHUNG (BMBF): *Projektumriss zum BMBF-Forschungsprojekt SOGRO*, 2009

- [Bund10] BUNDESWEHR, PRESSE- UND INFORMATIONSZENTRUM DES EINSATZFÜHRUNGSKOMMANDO DER: *Recce - Tornados im Einsatz - Eine Bilanz*. URL [http://www.einsatz.bundeswehr.de/portal/poc/einsatzbw?uri=ci%3Abw.bwde\\_einsatzbw.aktuelle\\_einsaetze.afghanistan.](http://www.einsatz.bundeswehr.de/portal/poc/einsatzbw?uri=ci%3Abw.bwde_einsatzbw.aktuelle_einsaetze.afghanistan.) - abgerufen am 2015-02-07
- [CBBG12] COMPTON, MICHAEL ; BARNAGHI, PAYAM ; BERMUDEZ, LUIS ; GARCÍA-CASTRO, RAÚL ; CORCHO, OSCAR ; COX, SIMON ; GRAYBEAL, JOHN ; HAUSWIRTH, MANFRED ; U. A.: The SSN ontology of the W3C semantic sensor network incubator group. In: *Web Semantics: Science, Services and Agents on the World Wide Web* Bd. 17 (2012), Nr. 0, S. 25–32
- [CDLS07] COWELL, ROBERT G ; DAWID, A PHILIP ; LAURITZEN, STEFFEN L ; SPIEGELHALTER, DAVID J: *Probabilistic Networks and Expert Systems: Exact Computational Methods for Bayesian Networks*. 1st. Aufl. : Springer Publishing Company, Incorporated, 2007 — ISBN 0387718230
- [Chen07] CHEN, C H: *Image Processing for Remote Sensing* : Taylor & Francis, 2007 — ISBN 9781420066647
- [Chic96] CHICKERING, DAVID MAXWELL: *Learning Bayesian Networks is NP-Complete*, 1996
- [ChKu03] CHONG, CHEE-YEE ; KUMAR, S P: Sensor networks: evolution, opportunities, and challenges. In: *Proceedings of the IEEE* Bd. 91 (2003), Nr. 8 — ISBN 0018-9219 VO - 91
- [CHLN09] COMPTON, MICHAEL ; HENSON, CORY ; LEFORT, LAURENT ; NEUHAUS, HOLGER ; SHETH, AMIT: A Survey of the Semantic Specification of Sensors. In: *Proc. Semantic Sensor Networks* (2009), S. 17
- [ChWL09] CHEN, HAI ; WANG, XIN-MIN ; LI, YAN: A Survey of Autonomous Control for UAV. In: *2009 International Conference on Artificial Intelligence and Computational Intelligence*, Ieee (2009), S. 267–271 — ISBN 978-1-4244-3835-8
- [CLHR14] CLIMENT-PÉREZ, PAU ; LAZARIDIS, GEORGIOS ; HUMMEL, GEORG ; RUSS, MARTIN ; MONEKOSSO, DOROTHYN. ; REMAGNINO, PAOLO: Telemetry-Based Search Window Correction for Airborne Tracking. In: BEBIS, G. ; BOYLE, R. ; PARVIN, B. ; KORACIN, D. ; MCMAHAN, R. ; JERALD, J. ; ZHANG, H. ; DRUCKER, S. ; U. A. (Hrsg.): *Advances in Visual Computing SE - 43, Lecture Notes in Computer Science*. Bd. 8887 : Springer International Publishing, 2014 — ISBN 978-3-319-14248-7, S. 457–466
- [CNSS06] COX, TIMOTHY H. ; NAGY, CHRISTOPHER J. ; SKOOG, MARK A. ; SOMERS, IVAN A.: *Civil UAV Capability Assessment - Interim Status Report*, 2006
- [Dasa97] DASARATHY, B V: Sensor fusion potential exploitation-innovative architectures and illustrative applications. In: *Proceedings of the IEEE* Bd. 85 (1997), Nr. 1 — ISBN 0018-9219 VO - 85
- [Dawe09] DAWES, DAVID G.: Sensor Fusion Payloads: The Key to Information-Rich Imaging. In: *Unmanned Systems* (2009), Nr. December 2009

- [DBKW21] DOSOVITSKIY, ALEXEY ; BEYER, LUCAS ; KOLESNIKOV, ALEXANDER ; WEISSENBORN, DIRK ; ZHAI, XIAOHUA ; UNTERTHINER, THOMAS ; DEGHANI, MOSTAFA ; MINDERER, MATTHIAS ; U. A.: An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale (2021)
- [DDSL10] DENG, JIA ; DONG, WEI ; SOCHER, RICHARD ; LI, LI-JIA ; KAI LI ; LI FEI-FEI: ImageNet: A large-scale hierarchical image database, Institute of Electrical and Electronics Engineers (IEEE) (2010), S. 248–255
- [Depa07] DEPARTMENT OF DEFENCE USA: Unmanned Systems Roadmap 2007 - 2032 (2007)
- [Depa13] DEPARTMENT OF DEFENCE USA: Unmanned Systems Integrated Roadmap 2013 - 2038 (2013)
- [DFRS19] DUDEK, ADRIAN ; FUNK, FRANZISKA ; RUSS, MARTIN ; STÜTZ, PETER: Cloud Detection System for UAV Sense and Avoid: First Results of Cloud Segmentation in a Simulation Environment. In: *2019 IEEE 5th International Workshop on Metrology for AeroSpace (MetroAeroSpace)*, 2019, S. 533–538
- [DGKS00] DOHERTY, P ; GRANLUND, G ; KUCHCINSKI, K ; SANDWALL, E ; NORDBERG, K ; SKARMAN, E: The WITAS Unmanned Aerial Vehicle Project. In: *Proceedings of the 14th European Conference on Artificial Intelligence - ECAI 2000* (2000), S. 747–755
- [DKWR14] DOHERTY, PATRICK ; KVARNSTROM, JONAS ; WZOREK, MARIUSZ ; RUDOL, PIOTR ; HEINTZ, FREDRIK ; CONTE, GIANPAOLO: HDRC3: A Distributed HybridDeliberative/Reactive Architecture for Unmanned Aircraft Systems. In: VALAVANIS, K. P. ; VACHTSEVANOS, G. J. (Hrsg.): *Handbook of Unmanned Aerial Vehicles SE - 118* : Springer Netherlands, 2014 — ISBN 978-90-481-9706-4, S. 849–952
- [Dona11] DONATH, DIANA: *Verhaltensanalyse der Beanspruchung des Operateurs in der Multi-UAV-Führung*, 2011
- [Dörn18] DÖRN, SEBASTIAN: *Programmieren für Ingenieure und Naturwissenschaftler: Intelligente Algorithmen und digitale Technologien*, eXamen.press : Springer Berlin Heidelberg, 2018 — ISBN 9783662543047
- [Durr88] DURRANT-WHYTE, HUGH F: Sensor models and multisensor integration. In: *The International Journal of Robotics Research* Bd. 7, Sage Publications (1988), Nr. 6, S. 97–113
- [EGKP18] EFTYCHIDIS, GEORGE ; GKOTSIS, ILIAS ; KOLIOS, PANAYIOTIS ; PELETIES, COSTAS: UAVs and Their Use in Servicing the Community. In: LEVENTAKIS, G. ; HABERFELD, M. R. (Hrsg.): *Community-Oriented Policing and Technological Innovations*. Cham : Springer International Publishing, 2018 — ISBN 978-3-319-89294-8, S. 119–131
- [EGWW10] EVERINGHAM, MARK ; VAN GOOL, LUC ; WILLIAMS, CHRISTOPHER K.I. ; WINN, JOHN ; ZISSERMAN, ANDREW: The pascal visual object classes (VOC) challenge. In: *International Journal of Computer Vision* Bd. 88 (2010), Nr. 2, S. 303–338



- [Erte16a] ERTEL, WOLFGANG: *Grundkurs Künstliche Intelligenz*, 2016 — ISBN 9783658135485
- [Erte16b] ERTEL, WOLFGANG: Schließen mit Unsicherheit. In: *Grundkurs Künstliche Intelligenz* : Springer Fachmedien Wiesbaden, 2016, S. 137–190
- [Esca13] ESCALANTE-RAMIREZ, BORIS: *Remote Sensing - Applications*, 2013
- [ESWH05] ESTEBAN, J ; STARR, A ; WILLETTS, R ; HANNAH, P ; BRYANSTON-CROSS, P: A Review of data fusion models and architectures: towards engineering guidelines. In: *Neural Computing and Applications* Bd. 14 (2005), Nr. 4, S. 273–281. — “The original publication is available at [www.springerlink.com](http://www.springerlink.com)”. Copyright Springer DOI: 10.1007/s00521-004-0463-7
- [Feue18] FEUERWEHR FRANKFURT: *SOGRO – Gemeinsame Rettungsdienst- und Sichtungübung der Feuerwehr Frankfurt und des DRK Frankfurt*, 2018
- [FiTh07] FINN V., JENSEN ; THOMAS D., NIELSEN: Building Models. In: *Bayesian Networks and Decision Graphs: February 8, 2007*. New York, NY : Springer New York, 2007 — ISBN 978-0-387-68282-2, S. 51–108
- [FIBr13] FLORO DA SILVA, NATASSYA BARLATE ; BRANCO, KALINKA REGINA LUCAS JAQUIE CASTELO: A new concept of VTOL as fixed-wing. In: *2013 International Conference on Unmanned Aircraft Systems, ICUAS 2013 - Conference Proceedings* (2013), S. 811–817 — ISBN 9781479908172
- [GaBH11] GASZCZAK, ANNA ; BRECKON, TOBY P. ; HAN, JIWAN: Real-time people and vehicle detection from UAV imagery (2011), S. 8–11 — ISBN 9780819484154
- [GDDM14] GIRSHICK, ROSS ; DONAHUE, JEFF ; DARRELL, TREVOR ; MALIK, JITENDRA: Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation. In: *2014 IEEE Conference on Computer Vision and Pattern Recognition*, 2014, S. 580–587
- [GGBF02] GUSTAFSSON, FREDRIK ; GUNNARSSON, FREDRIK ; BERGMAN, NICLAS ; FORSELL, URBAN ; JANSSON, JONAS ; KARLSSON, RICKARD ; NORDLUND, P-J: Particle filters for positioning, navigation, and tracking. In: *Signal Processing, IEEE Transactions on* Bd. 50, IEEE (2002), Nr. 2, S. 425–437
- [GiRi05] GIARRATANO, JOSEPH C ; RILEY, GARY D: *Expert Systems: Principles and Programming*. Pacific Grove, CA, USA : Brooks/Cole Publishing Co., 2005 — ISBN 0534384471
- [GoFH90] GOTTLob, GEORG ; FRUHWIRTH, THOMAS ; HORN, WERNER: *Expertensysteme*, 1990 — ISBN 9783211822210
- [GoKM09] GOERZEN, C. ; KONG, Z. ; METTLER, B.: A Survey of Motion Planning Algorithms from the Perspective of Autonomous UAV Guidance. In: *Journal of Intelligent and Robotic Systems* Bd. 57, Springer Netherlands (2009), Nr. 1–4, S. 65–100
- [GöSu14] GÖKTOĞAN, ALIHAYDAR ; SUKKARIEH, SALAH: Autonomous Remote Sensing of Invasive Species from Robotic Aircraft. In: VALAVANIS, K. P. ; VACHTSEVANOS, G. J.

- (Hrsg.): *Handbook of Unmanned Aerial Vehicles SE - 72* : Springer Netherlands, 2014 — ISBN 978-90-481-9706-4, S. 2813–2834
- [GPJM08] GOMEZ, MARIO ; PREECE, ALUN ; JOHNSON, MATTHEW P. ; DE MEL, GEETH ; VASCONCELOS, WAMBERTO ; GIBSON, CHRISTOPHER ; BAR-NOY, AMOTZ ; BOROWIECKI, KONRAD ; U. A.: An Ontology-Centric Approach to Sensor-Mission Assignment. In: GANGEMI, A. ; EUZENAT, J. (Hrsg.): *Knowledge Engineering: Practice and Patterns SE - 30, Lecture Notes in Computer Science*. Bd. 5268 : Springer Berlin Heidelberg, 2008 — ISBN 978-3-540-87695-3, S. 347–363
- [Grad16] GRADY, JEFFREY O: Chapter 6 - Verification Process Design for a Program. In: GRADY, J. O. (Hrsg.): *System Verification (Second Edition)*. Second Edi. Aufl. : Academic Press, 2016 — ISBN 978-0-12-804221-2, S. 155–180
- [GrAn11] GREWAL, MOHINDER S ; ANDREWS, ANGUS P: *Kalman filtering: theory and practice using MATLAB* : John Wiley & Sons, 2011 — ISBN 1118210468
- [Groc02] GROCHOLSKY, BEN: *Information-Theoretic Control of Multiple Sensor Platforms* (2002)
- [GuGJ13] GUPTA, SG ; GHONGE, MM ; JAWANDHIYA, PM: Review of Unmanned Aircraft System (UAS). In: *International Journal of Advanced Research in Computer Engineering & Technology (IJARCET)* Bd. 2 (2013), Nr. 4, S. 1646–1658
- [HaBD98] HARRIS, C J ; BAILEY, A ; DODD, T J: Multi-Sensor Data Fusion in Defence and Aerospace. In: *The Aeronautical Journal* Bd. 102 (1998), Nr. 1015, S. 229–244
- [Hadd09] HADDON, DAVID: *Airworthiness certification of unmanned aircraft systems (UAS)*, 2009
- [HaLl97] HALL, D L ; LLINAS, J: An introduction to multisensor data fusion. In: *Proceedings of the IEEE* Bd. 85 (1997), Nr. 1 — ISBN 0018-9219 VO - 85
- [HaMc04] HALL, DAVID LEE ; MCMULLEN, SONYA A H: *Mathematical techniques in multisensor data fusion* : Artech House, 2004 — ISBN 1580533353
- [Heck08] HECKERMAN, DAVID: A tutorial on learning with Bayesian networks. In: *Innovations in Bayesian networks* : Springer, 2008, S. 33–82
- [HeCo11] HERO, ALFRED O. ; COCHRAN, DOUGLAS: Sensor management: Past, present, and future. In: *IEEE Sensors Journal* Bd. 11 (2011), Nr. 12, S. 3064–3075
- [Hell19] HELLERT, CHRISTIAN: *Algorithmenauswahl für den adaptiven Sensoreinsatz an Bord unbemannter Luftfahrzeuge*, Universität der Bundeswehr München, 2019
- [HGPB10] HEIZMANN, M. ; GHETA, I. ; PUENTE LEON, F ; BEYERER, J.: Sensoreinsatzplanung und Informationsfusion zur Umgebungsexploration - Sensor Management and Information Fusion for Environment Exploration. In: *Technisches Messen* Bd. 10 (2010), S. 558–567
- [HHXB18] HRABIA, CHRISTOPHER EYK ; HESSLER, AXEL ; XU, YUAN ; BREHMER, JAN ;

- ALBAYRAK, SAHIN: EffFeu project: Efficient operation of unmanned aerial vehicles for industrial fire fighters. In: *DroNet 2018 - Proceedings of the 2018 ACM International Conference on Mobile Systems, Applications and Services*, 2018 — ISBN 9781450358392, S. 33–38
- [Hil14] HILLER: *Introduction to Operations Research*, 2014 — ISBN 9192631770
- [HMTF11] HENG, LIONEL ; MEIER, LORENZ ; TANSKANEN, PETRI ; FRAUNDORFER, FRIEDRICH ; POLLEFEYS, MARC: Autonomous obstacle avoidance and maneuvering on a vision-guided MAV using on-board processing. In: *Proceedings - IEEE International Conference on Robotics and Automation* (2011), S. 2472–2477 — ISBN 9781612843865
- [HoSc15] HONECKER, FABIAN ; SCHULTE, AXEL: Evidenzbasierte Pilotentätigkeitserkennung unter Berücksichtigung unterschiedlich zuverlässiger Beobachtungen. In: *57. Fachausschusssitzung Anthropotechnik der DGLR: Kooperation und kooperative Systeme in der Fahrzeug- und Prozessführung* Bd. 9 (2015), S. 115–130 — ISBN 9783932182839
- [HRSS12] HUMMEL, GEORG ; RUSS, MARTIN ; STÜTZ, PETER ; SOLDATOS, JOHN ; ROSSI, LORENZO ; KNAPE, THOMAS ; UTASI, ÁKOS ; KOVÁCS, LEVENTE ; U. A.: Intelligent Multi Sensor Fusion System for Advanced Situation Awareness in Urban Environments. In: ASCHENBRUCK, N. ; MARTINI, P. ; MEIER, M. ; TÖLLE, J. (Hrsg.): *Future Security, Communications in Computer and Information Science*. Bd. 318 : Springer, 2012 — ISBN 978-3-642-33160-2, S. 93–104
- [HSRS12] HELLERT, C ; SMIRNOV, D ; RUSS, M ; STÜTZ, P: A High Level Active Perception Concept for UAV Mission Scenarios. In: *Deutscher Luft- und Raumfahrtkongress (DLRK)* (2012), S. 1–9
- [Hube09a] HUBER, MARCO: *Probabilistic Framework for Sensor Management*, Universität Karlsruhe (TH), 2009
- [Hube09b] HUBER, MARCO: *Probabilistic framework for sensor management*, Universitätsverlag Karlsruhe, 2009
- [Hüb13] HÜBNER, GERHARD: *Stochastik: eine anwendungsorientierte Einführung für Informatiker, Ingenieure und Mathematiker* : Springer-Verlag, 2013 — ISBN 3322969584
- [Hut07] HUTCHINGS, TIM: Architecting UAV sense & avoid systems. In: ... *Systems, 2007 Institution of ...* (2007), Nr. 1
- [HWCC23] HAN, K ; WANG, Y ; CHEN, H ; CHEN, X ; GUO, J ; LIU, Z ; TANG, Y ; XIAO, A ; U. A.: A Survey on Vision Transformer. In: *IEEE Transactions on Pattern Analysis & Machine Intelligence* Bd. 45. Los Alamitos, CA, USA, IEEE Computer Society (2023), Nr. 01, S. 87–110
- [Jäh05] JÄHNE, BERND: *Digitale Bildverarbeitung*. 6. Auflage. Aufl. Berlin/Heidelberg : Springer-Verlag, 2005 — ISBN 3-540-24999-0

- [Jeni13] JENIE, YAZDI IBRAHIM: *Autonomous collision avoidance system for UAVs*, 2013
- [Jord98] JORDAN, MICHAEL IRWIN: *Learning in Graphical Models*. Bd. 89 : Springer Science & Business Media, 1998
- [JoXi03] JOHANSSON, L RONNIE M ; XIONG, NING: Perception management: an emerging concept for information fusion. In: *Information Fusion* Bd. 4, Elsevier (2003), Nr. 3, S. 231–234
- [KaBl08] KAHLER, B ; BLASCH, E: Sensor Management Fusion Using Operating Conditions. In: *Aerospace and Electronics Conference, 2008. NAECON 2008. IEEE National* (2008) — ISBN 7964-0977 VO -
- [KACH15] KOCHENDERFER, MYKEL J ; AMATO, CHRISTOPHER ; CHOWDHARY, GIRISH ; HOW, JONATHAN P ; REYNOLDS, HAYLEY J DAVISON ; THORNTON, JASON R ; TORRES-CARRASQUILLO, PEDRO A ; ÜRE, N KEMAL ; U. A.: *Decision Making Under Uncertainty: Theory and Application*. 1st. Aufl. : The MIT Press, 2015 — ISBN 0262029251
- [KBBK15a] KRUSE, RUDOLF ; BORGELT, CHRISTIAN ; BRAUNE, CHRISTIAN ; KLAUWONN, FRANK ; MOEWES, CHRISTIAN ; STEINBRECHER, MATTHIAS ; KRUSE, RUDOLF ; BORGELT, CHRISTIAN ; U. A.: *Grundlagen der Wahrscheinlichkeits- und Graphentheorie*. In: *Computational Intelligence: Eine methodische Einführung in Künstliche Neuronale Netze, Evolutionäre Algorithmen, Fuzzy-Systeme und Bayes-Netze* : Springer Fachmedien Wiesbaden, 2015, S. 411–438
- [KBBK15b] KRUSE, RUDOLF ; BORGELT, CHRISTIAN ; BRAUNE, CHRISTIAN ; KLAUWONN, FRANK ; MOEWES, CHRISTIAN ; STEINBRECHER, MATTHIAS: *Computational Intelligence: Eine methodische Einführung in Künstliche Neuronale Netze, Evolutionäre Algorithmen, Fuzzy-Systeme und Bayes-Netze* : Springer Vieweg, 2015
- [KBSF20] KOSSIAKOFF, A ; BIEMER, S M ; SEYMOUR, S J ; FLANIGAN, D A: *Systems Engineering Principles and Practice, Wiley Series in Systems Engineering and Management* : Wiley, 2020 — ISBN 9781119516668
- [Kend12] KENDOUL, FARID: Survey of advances in guidance, navigation, and control of unmanned rotorcraft systems. In: *Journal of Field Robotics* Bd. 29 (2012), Nr. 2, S. 315–378
- [KHSL14] KONDAK, KONSTANTIN ; HUBER, FELIX ; SCHWARZBACH, MARC ; LAIACKER, MAXIMILIAN ; SOMMER, DOMINIK ; BEJAR, MANUEL ; OLLERO, ANÍBAL: Aerial manipulation robot composed of an autonomous helicopter and a 7 degrees of freedom industrial manipulator. In: *IEEE International Conference on Robotics and Automation*, 2014 — ISBN 9781479936847, S. 2107–2112
- [KKAS13] KONDAK, KONSTANTIN ; KRIEGER, KAI ; ALBU-SCHAEFFER, ALIN ; SCHWARZBACH, MARC ; LAIACKER, MAXIMILIAN ; MAZA, IVAN ; RODRIGUEZ-CASTANO, ANGEL ; OLLERO, ANIBAL: Closed-loop behavior of an autonomous helicopter equipped with a robotic arm for aerial manipulation tasks. In: *International Journal of Advanced Robotic Systems* Bd. 10 (2013)
- [Klei04] KLEIN, LAWRENCE A: *Sensor and Data Fusion: A Tool for Information*

- Assessment and Decision Making* : Spie Press Bellingham, 2004 — ISBN 0819454354
- [Kno199] KNOLL, ALOIS: *Autonomie für situierte Robotersysteme: Stand und Entwicklungslinien*, 1999
- [Kolo14] KOLODNER, JANET: *Case-based reasoning* : Morgan Kaufmann, 2014
- [KOMK14] KONDAK, KONSTANTIN ; OLLERO, ANÍBAL ; MAZA, IVAN ; KRIEGER, KAI ; ALBU-SCHAEFFER, ALIN ; SCHWARZBACH, MARC ; LAIACKER, MAXIMILIAN: Unmanned Aerial Systems Physically Interacting with the Environment: Load Transportation, Deployment, and Aerial Manipulation. In: VALAVANIS, K. P. ; VACHTSEVANOS, G. J. (Hrsg.): *Handbook of Unmanned Aerial Vehicles SE - 77* : Springer Netherlands, 2014 — ISBN 978-90-481-9706-4, S. 2755–2785
- [KoNi10] KORB, K B ; NICHOLSON, A E: *Bayesian Artificial Intelligence, Chapman & Hall/CRC Computer Science & Data Analysis* : CRC Press, 2010 — ISBN 9781439815922
- [Krog03] KROGMANN, UWE K.: Situation Awareness Concepts and Technologies. In: *Applications , Concepts and Technologies for Future Tactical UAVs (RTO-EN-025)*, 2003
- [KrRS20] KRUMP, MICHAEL ; RUSS, MARTIN ; STÜTZ, PETER: Deep Learning Algorithms for Vehicle Detection on UAV Platforms: First Investigations on the Effects of Synthetic Training. In: *Model. Simul. Auton. Syst. MESAS 2019. Lect. Notes Comput. Sci.*, 2020, S. 50–70
- [Krum23] KRUMP MICHAEL; STÜTZ, PETER: Deep Learning Based Vehicle Detection on Real and Synthetic Aerial Images : Training Data Composition and Statistical Influence Analysis. In: *Sensors* Bd. 23 (2023), Nr. 7, S. 3769
- [KSST82] KAHNEMAN, DANIEL ; SLOVIC, STEWART PAUL ; SLOVIC, PAUL ; TVERSKY, AMOS: *Judgment under uncertainty: Heuristics and biases* : Cambridge university press, 1982
- [KSZQ19] KHAN, ASIFULLAH ; SOHAIL, ANABIA ; ZAHOORA, UMME ; QURESHI, AQSA SAEED: A Survey of the Recent Architectures of Deep Convolutional Neural Networks. In: *Artificial Intelligence Review* Bd. 53, Springer Science and Business Media B.V. (2019), Nr. 8, S. 5455–5516
- [KuDe13] KUENZER, CLAUDIA ; DECH, STEFAN: *Thermal remote sensing Sensors, Methods, Applications*. Bd. 17, 2013 — ISBN 9789400766389
- [LaGS14] LAUX, HELMUT ; GILLENKIRCH, ROBERT M. ; SCHENK-MATHES, HEIKE: *Entscheidungstheorie*, 2014 — ISBN 3642235115
- [LaMa05] LAGOUDAKIS, M ; MARKAKIS, EVANGELOS: Auction-based multi-robot routing. In: *Science and Systems* (2005)
- [Lang13] DE LANGE, NORBERT: *Geoinformatik*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2013 — ISBN 978-3-642-34806-8

- [Laur96] LAURITZEN, STEFFEN L: *Graphical models*. Bd. 17 : Clarendon Press, 1996
- [LeMi07] LEE, J.S. ; MILLER, L.E.: INCOSE - Systems Engineering Handbook. In: *Systems Engineering* (2007), Nr. August, S. 304
- [LGGH17] LIN, TSUNG YI ; GOYAL, PRIYA ; GIRSHICK, ROSS ; HE, KAIMING ; DOLLAR, PIOTR: Focal Loss for Dense Object Detection. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* Bd. 42, IEEE Computer Society (2017), Nr. 2, S. 318–327
- [LiHL08] LIGGINS II, MARTIN ; HALL, DAVID ; LLINAS, JAMES: *Handbook of multisensor data fusion: theory and practice* : CRC press, 2008 — ISBN 1420053094
- [Lind03] LINDER, WILFRIED: *Digital Photogrammetry*. Berlin, Heidelberg : Springer Berlin Heidelberg, 2003 — ISBN 978-3-662-06727-7
- [LILH08] LLINAS, JAMES ; LIGGINS, MARTIN E. ; HALL, DAVID L.: *Handbook of Multisensor Data Fusion: Theory and Practice*, 2008 — ISBN 9781420053098
- [LMBH14] LIN, TSUNG YI ; MAIRE, MICHAEL ; BELONGIE, SERGE ; HAYS, JAMES ; PERONA, PIETRO ; RAMANAN, DEVA ; DOLLÁR, PIOTR ; ZITNICK, C. LAWRENCE: Microsoft COCO: Common Objects in Context. In: *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)* Bd. 8693 LNCS, Springer Verlag (2014), Nr. PART 5, S. 740–755
- [LNSH23] LIEGL, CHRISTIAN JOHANN ; NICKCHEN, TOBIAS ; STRUNZ, EVA ; HORN, ANDREAS ; COPPENRATH, ALEXANDER ; UYSAL, UGUR ; RUSS, MARTIN ; LUFT, FLORIAN: Simulation: The Great Enabler? In: MAZAL, J. ; FAGIOLINI, A. ; VAŠÍK, P. ; BRUZZONE, A. ; PICKL, S. ; NEUMANN, V. ; STODOLA, P. ; LO STORTO, S. (Hrsg.): *Modelling and Simulation for Autonomous Systems*. Cham : Springer International Publishing, 2023 — ISBN 978-3-031-31268-7, S. 312–325
- [Löff85] LÖFFLER, ERNST: *Geographie und Fernerkundung: eine Einführung in die geographische Interpretation von Luftbildern und modernen Fernerkundungsdaten*, 1985 — ISBN 3443071406
- [LuCh12] LUO, REN C. ; CHANG, CHIH-CHIA: Multisensor Fusion and Integration: A Review on Approaches and Its Applications in Mechatronics. In: *IEEE Transactions on Industrial Informatics* Bd. 8 (2012), Nr. 1, S. 49–60
- [Luft13] LUFTWAFFE, PRESSE- UND INFORMATIONSZENTRUM DER: *Aufklärungs - Fähigkeiten der Luftwaffe im Einsatz am Beispiel Aufklärungstornado*. URL <http://www.luftwaffe.de/portal/poc/luftwaffe?uri=ci%3Abw.lw.waff.jets.torn>. - abgerufen am 2015-02-09
- [LuKa89] LUO, REN C ; KAY, MICHAEL G: Multisensor integration and fusion in intelligent systems. In: *Systems, Man and Cybernetics, IEEE Transactions on* Bd. 19, IEEE (1989), Nr. 5, S. 901–931
- [LuKa90] LUO, R.C. ; KAY, M.G.: A tutorial on multisensor integration and fusion. In: *[Proceedings] IECON '90: 16th Annual Conference of IEEE Industrial Electronics*

- Society, Ieee* (1990), S. 707–722 — ISBN 0-87942-600-4
- [LWZF20] LIU, MINGJIE ; WANG, XIANHAO ; ZHOU, ANJIAN ; FU, XIUYUAN ; MA, YIWEI ; PIAO, CHANGHAO: UAV-YOLO: Small Object Detection on Unmanned Aerial Vehicle Perspective. In: *Sensors 2020, Vol. 20, Page 2238* Bd. 20, Multidisciplinary Digital Publishing Institute (2020), Nr. 8, S. 2238
- [MaDu95] MANYIKA, JAMES ; DURRANT-WHYTE, HUGH: *Data Fusion and Sensor Management: A Decentralized Information-Theoretic Approach*. Upper Saddle River, NJ, USA : Prentice Hall PTR, 1995 — ISBN 0133031322
- [MAJL13] MOHAMED, NADER ; AL-JAROODI, JAMEELA ; JAWHAR, IMAD ; LAZAROVA-MOLNAR, SANJA: A Service-Oriented Middleware for Building Collaborative UAVs. In: *Journal of Intelligent & Robotic Systems* Bd. 74 (2013), Nr. 1–2, S. 309–321
- [Marq11] MARQUES, O: *Practical image and video processing using MATLAB* (2011) — ISBN 9780470048153
- [Mayb11] MAYBURY, MARK T.: *Remotely Piloted Aircraft: Future Air Force Science and Technology*, 2011
- [MCMF06] MERINO, LUIS ; CABALLERO, FERNANDO ; MARTÍNEZ-DE DIOS, J R ; FERRUZ, JOAQUÍN ; OLLERO, ANÍBAL: A cooperative perception system for multiple UAVs: Application to automatic detection of forest fires. In: *Journal of Field Robotics* Bd. 23, Wiley Subscription Services, Inc., A Wiley Company (2006), Nr. 3–4, S. 165–184
- [Meit08] MEITINGER, CLAUDIA: *Kognitive Automation zur kooperativen UAV-Flugführung*, 2008
- [MFEX09] MEJIAS, LUIS ; FITZGERALD, DL ; ENG, PC ; XI, L: Forced landing technologies for unmanned aerial vehicles: towards safer operations. In: *Aerial Vehicles*, 2009, S. 415–442
- [MiDe07] MITTAL, SHASHI ; DEB, KALYANMOY: Three-dimensional offline path planning for UAVs using multiobjective evolutionary algorithms. In: *Proceedings of the Congress on Evolutionary Computation (CEC-2007), (Singapore)*, 2007, S. 3195–3202
- [Mitic05] MITCHELL, HARVEY B: *Multi-sensor data fusion* : Springer, 2005 — ISBN 3540715592
- [MKBO10] MAZA, I ; KONDAK, K ; BERNARD, M ; OLLERO, A: Multi-UAV cooperation and control for load transportation and deployment. In: *Journal of Intelligent and Robotic ...* (2010)
- [MoSS18] MORAWIETZ, STEN ; STROHAL, MICHAEL ; STÜTZ, PETER: A Decision Support System for the Mission-Based Evaluation of Aerial Platforms: Advancements and Final Validation Results. In: *2018 Aviation Technology, Integration, and Operations Conference*, 2018, S. 3975
- [MTFP11] MEIER, LORENZ ; TANSKANEN, PETRI ; FRAUNDORFER, FRIEDRICH ; POLLEFEYS, MARC: PIXHAWK: A system for autonomous flight using onboard computer vision. In:



- Proceedings - IEEE International Conference on Robotics and Automation* (2011)  
— ISBN 9781612843865
- [MuSh12] MURPHY, R ; SHIELDS, J: The role of autonomy in DoD systems (2012), Nr. July
- [NeOt04] NEAPOLITAN, RICHARD E ; OTHERS: *Learning bayesian networks*. Bd. 38 :  
Pearson Prentice Hall Upper Saddle River, NJ, 2004
- [NgNg00] NG, G.W ; NG, K.H: Sensor management – what, why and how. In: *Information Fusion* Bd. 1 (2000), Nr. 2, S. 67–75
- [Niet13] NIETHAMMER, UWE: *UAV-basierte Fernerkundungsmethoden der Aerogeophysik für die hochauflösende Beobachtung von alpinen Rutschhängen*, 2013
- [NKSU10] NONAMI, KENZO ; KENDOU, FARID ; SUZUKI, SATOSHI ; WANG, WEI ;  
NAKAZAWA, DAISUKE: Vision-Based Navigation and Visual Servoing of Mini Flying  
Machines. In: *Autonomous Flying Robots: Unmanned Aerial Vehicles and Micro Aerial  
Vehicles*, 2010, S. 267–302
- [Nof09] NOF, SHIMON Y.: *Springer Handbook of Automation*, 2009
- [Nort05] NORTH ATLANTIC TREATY ORGANIZATION: *NATO Intelligence, Surveillance,  
and Reconnaissance (ISR) Interoperability Architecture (NIIA) VOLUME 1:  
Architecture Description*. Bd. 1, 2005 — ISBN 7035882669
- [NSKB05] NYGÅRDS, JONAS ; SKOGLAR, PER ; KARLHOLM, JÖRGEN ; BJÖRSTRÖM, RICKARD  
; ULVKLO, MORGAN: *Towards Concurrent Sensor and Path Planning: A Survey of  
Planning Methods Applicable to UAV Surveillance*, 2005
- [OCCH08] OERTEL, CARSTEN ; COLDER, BRIAN ; COLOMBE, JEFFREY ; HIGH, JULIA ;  
INGRAM, MICHAEL ; SALLEE, PHIL: Current challenges in automating visual perception.  
In: *Proceedings - Applied Imagery Pattern Recognition Workshop* (2008), S. 1–8  
— ISBN 9781424431250
- [OIMa07] OLLERO, ANÍBAL ; MAZA, IVÁN ; OLLERO, A. ; MAZA, I. (Hrsg.): *Multiple  
Heterogeneous Unmanned Aerial Vehicles, Springer Tracts in Advanced Robotics*. Bd.  
37 : Springer Berlin Heidelberg, 2007 — ISBN 978-3-540-73957-9
- [OnSc10] ONKEN, REINER ; SCHULTE, AXEL: *System-ergonomic design of cognitive  
automation. Dual-mode cognitive design of vehicle guidance and control work systems*,  
2010
- [Ouas07] OUASTI, MORAD: *Remote Sensing and the Military*, 2007
- [Pane08] PANELLA, ISABELLA: High-level functional architecture for sensor management  
system. In: *Proceedings BLISS 2008 - 2008 ECSIS Symposium on Bio-inspired,  
Learning, and Intelligent Systems for Security* (2008), S. 107–110  
— ISBN 9780769532653
- [Papu16] PAPULA, LOTHAR: *Mathematik für Ingenieure und Naturwissenschaftler Band 3:  
Vektoranalysis, Wahrscheinlichkeitsrechnung, Mathematische Statistik, Fehler-und*

*Ausgleichsrechnung* : Springer-Verlag, 2016

- [Pear09] PEARL, JUDEA: *Causality* : Cambridge university press, 2009
- [Pear88] PEARL, JUDEA: *Probabilistic Reasoning in Intelligent Systems: Networks of Plausible Inference*, 1988 — ISBN 0-934613-73-7
- [Pel03] PELLKOFER, DIPL MARTIN: *Verhaltensentscheidung für autonome Fahrzeuge mit Blickrichtungssteuerung*, 2003
- [PiCD08] PINTO, N ; COX, DD ; DICARLO, JJ: Why is real-world visual object recognition hard? In: *PLoS computational biology* (2008)
- [Prat94] PRATT, WILLIAM K.: *Digital Image Processing*. Bd. 19. Upper Saddle River, NJ, USA : Prentice-Hall, Inc., 1994 — ISBN 013168728X
- [PrGo08] PREECE, ALUN ; GOMEZ, MARIO: Matching sensors to missions using a knowledge-based approach. In: *SPIE Defense ...* Bd. 44 (2008), Nr. 0
- [PTWW15] PHAM, LONG ; TEICH, JEFFREY ; WALLENIUS, HANNELE ; WALLENIUS, JYRKI: Multi-attribute online reverse auctions: Recent research trends. In: *European Journal of Operational Research* Bd. 242 (2015), Nr. 1, S. 1–9
- [Pupp90] PUPPE, FRANK: *Problemlösungsmethoden in Expertensystemen*, 1990 — ISBN 9783642761331
- [Puri05] PURI, ANUJ: A Survey of Unmanned Aerial Vehicles (UAV) for Traffic Surveillance. In: *Technical Paper* (2005), S. 1–29
- [Raol09] RAOL, JITENDRA R: *Multi-Sensor Data Fusion with MATLAB* : CRC Press, 2009 — ISBN 1439800057
- [Raus13] RAUSCHERT, DIPL ANDREAS: *Kognitives Assistenzsystem zur Führung unbemannter Luftfahrzeuge in bemannt-unbemannten Flugmissionen*, 2013
- [RBAG10] RUIJIE HE ; BACHRACH, A. ; ACHELNIK, M. ; GERAMIFARD, A. ; GURDAN, D. ; PRENTICE, S. ; STUMPF, J. ; ROY, N.: On the Design and Use of a Micro Air Vehicle to Track and Avoid Adversaries. In: *The International Journal of Robotics Research* Bd. 29 (2010), S. 529–546 — ISBN 0278-3649
- [RBFT99] ROY, NICHOLAS ; BURGARD, WOLFRAM ; FOX, DIETER ; THRUN, SEBASTIAN: Coastal navigation - mobile robot navigation with uncertainty in dynamic environments. In: *Proceedings - IEEE International Conference on Robotics and Automation*. Bd. 1, 1999, S. 35–40
- [RCBS13] ROYO, PABLO ; CUADRADO, RAUL ; BARRADO, CRISTINA ; SALAMI, ESTHER ; PEREZ-BATLLE, MARC ; PASTOR, ENRIC: Towards the automation of the UAS mission management. In: *2013 IEEE/AIAA 32nd Digital Avionics Systems Conference (DASC)* : IEEE, 2013 — ISBN 978-1-4799-1538-5, S. 6D6-1-6D6-14
- [RDGF15] REDMON, JOSEPH ; DIVVALA, SANTOSH ; GIRSHICK, ROSS ; FARHADI, ALI: You

- Only Look Once: Unified, Real-Time Object Detection. In: *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition* Bd. 2016-December, IEEE Computer Society (2015), S. 779–788 — ISBN 9781467388504
- [Reif00] REIF, GERALD: *Moderne Aspekte des Wissensverarbeitung*, Technische Universität Graz, 2000
- [Rese14] RESEARCH, DHL TREND: *Unmanned Aerial Vehicles in Logistics. A DHL perspective on implications and use cases for the logistics industry.*, 2014
- [RHGS15] REN, SHAOQING ; HE, KAIMING ; GIRSHICK, ROSS ; SUN, JIAN: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. In: CORTES, C. ; LAWRENCE, N. ; LEE, D. ; SUGIYAMA, M. ; GARNETT, R. (Hrsg.): *Advances in Neural Information Processing Systems*. Bd. 28 : Curran Associates, Inc., 2015
- [RHGS17] REN, SHAOQING ; HE, KAIMING ; GIRSHICK, ROSS ; SUN, JIAN: Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. In: *IEEE Transactions on Pattern Analysis and Machine Intelligence* Bd. 39 (2017), Nr. 6, S. 1137–1149
- [RiAG04] RISTIC, BRANKO ; ARULAMPALAM, SANJEEV ; GORDON, NEIL: *Beyond the Kalman filter: Particle filters for tracking applications*. Bd. 685 : Artech house Boston, 2004
- [RiSc13] RIESBECK, CHRISTOPHER K ; SCHANK, ROGER C: *Inside case-based reasoning : Psychology Press*, 2013
- [RKPC02] RATHBUN, DAVID ; KRAGELUND, SEAN ; PONGPUNWATTANA, ANAWAT ; CAPOZZI, BRIAN: An evolution based path planning algorithm for autonomous motion of a UAV through uncertain environments. In: *Digital Avionics Systems Conference, 2002. Proceedings. The 21st*. Bd. 2, 2002, S. 8D2--1
- [RLHW09] RANGO, ALBERT ; LALIBERTE, ANDREA ; HERRICK, JEFFREY E. ; WINTERS, CRAIG ; HAVSTAD, KRIS ; STEELE, CAITI ; BROWNING, DAWN: Unmanned aerial vehicle-based remote sensing for rangeland assessment, monitoring, and management. In: *Journal of Applied Remote Sensing* Bd. 3 (2009), Nr. August, S. 033542 — ISBN 1931-3195
- [RLPB08] ROYO, P ; LÓPEZ, J ; PASTOR, E ; BARRADO, C: Service abstraction layer for UAV flexible application development. In: *46th AIAA Aerospace Sciences ...* (2008)
- [RMEM11] RODRIGUES, DOUGLAS ; DE MELO PIRES, RAYNER ; ESTRELLA, JULIO CÉZAR ; MARCONATO, EMERSON ALBERTO ; DE TRINDE, ONOFRE ; CASTELO BRANCO, KALINKA REGINA LUCAS JAQUIE: Using SOA in critical-embedded systems. In: *Proceedings - 2011 IEEE International Conferences on Internet of Things and Cyber, Physical and Social Computing, iThings/CPSCoM 2011* (2011), S. 733–738 — ISBN 9780769545806
- [Robl00] ROBL, CHRISTIAN: *Aufgabenorientierte Kopplung von Sensoren mit unterschiedlichen Abtasteigenschaften*, 2000
- [RSHS13] RUSS, MARTIN ; SCHMITT, MARC ; HELLERT, CHRISTIAN ; STÜTZ, PETER:

- Airborne sensor and perception management: Experiments and Results for surveillance UAS. In: *AIAA Infotech@Aerospace (I@A) Conference*. Reston, Virginia, American Institute of Aeronautics and Astronautics (2013), S. 1–16
- [RuHS18] RUSS, MARTIN ; HELLERT, CHRISTIAN ; STÜTZ, PETER: Sensor & Perception Management for UAVs: Foundation and Application. In: *Workshop on AI and Cognitive Technologies for Radar, Comms and EW*. Brüssel : EDA, 2018
- [RuNo20] RUSSELL, STUART ; NORVIG, PETER: *Artificial Intelligence: A Modern Approach*. 4th Editio. Aufl., 2020
- [RuPu07] RUSER, HEINRICH ; PUENTE LEÓN, FERNANDO: Informationsfusion—Eine Übersicht (Information Fusion—An Overview). In: *tm—Technisches Messen* Bd. 74 (2007), Nr. 3, S. 93–102
- [RuSt12] RUSS, MARTIN ; STÜTZ, PETER: Airborne sensor and perception management: A conceptual approach for surveillance UAS. In: *Information Fusion (15th FUSION)*, 2012
- [RuSt13a] RUSS, MARTIN ; STUTZ, P: Application of a probabilistic market-based approach in UAV sensor & perception management. In: *Information Fusion (FUSION), 2013 16th ...* (2013)
- [RuSt13b] RUSS, MARTIN ; STÜTZ, PETER: Application of a Probabilistic Market-based Approach in UAV Sensor & Perception Management. In: *Information Fusion (16th FUSION)*, 2013
- [RuSt23] RUSS, MARTIN ; STÜTZ, PETER: Airborne Sensor and Perception Management: Context-Based Selection of Specialized CNNs to Ensure Reliable and Trustworthy Object Detection. In: MAZAL, J. ; FAGIOLINI, A. ; VAŠÍK, P. ; BRUZZONE, A. ; PICKL, S. ; NEUMANN, V. ; STODOLA, P. ; LO STORTO, S. (Hrsg.): *Modelling and Simulation for Autonomous Systems*. Cham : Springer International Publishing, 2023 — ISBN 978-3-031-31268-7, S. 182–206
- [RVSO12] RUSS, MARTIN ; VOHLA, MICHAEL ; STÜTZ, PETER ; OYOUNG, SIU: LIDAR-based Object Detection on Small UAV: Integration, Experimentation and Results. In: *AIAA-Infotech*, 2012
- [SaRe15] SAITO, TAKAYA ; REHMSMEIER, MARC: The Precision-Recall Plot Is More Informative than the ROC Plot When Evaluating Binary Classifiers on Imbalanced Datasets. In: *PLOS ONE* Bd. 10, Public Library of Science (2015), Nr. 3, S. 1–21
- [SaSh16] SADAOUI, SAMIRA ; SHIL, SHUBHASHIS KUMAR: A Multi-Attribute Auction Mechanism based on Conditional Constraints and Conditional Qualitative Preferences. In: *Journal of Theoretical and Applied Electronic Commerce Research* Bd. 11 (2016), Nr. 1, S. 1–25
- [ScCS10] SCHERER, SEBASTIAN ; CHAMBERLAIN, LYLE ; SINGH, SANJIV: Online Assessment of Landing Sites. In: *AIAA Infotech@Aerospace 2010* (2010), Nr. April, S. 1–14 — ISBN 978-1-60086-963-1
- [ScCS12] SCHERER, SEBASTIAN ; CHAMBERLAIN, LYLE ; SINGH, SANJIV: Autonomous

- landing at unprepared sites by a full-scale helicopter. In: *Robotics and Autonomous Systems* Bd. 60 (2012)
- [ScFG06] SCHRAGE, DAN ; FARNHAM, CHRISTOPHER ; GONSALVES, PAUL G: A market-based optimization approach to sensor and resource management. In: *Proceedings of SPIE* (2006) — ISBN 0819462853
- [Scot05] SCOTT E, UMBAUGH: *Computer Imaging: Digital Image Analysis and Processing* : CRC Press, 2005
- [ScTS02] SCHURGERS, C ; TSIATSI, V ; SRIVASTAVA, MB: STEM: Topology management for energy efficient sensor networks. In: *Aerospace Conference Proceedings, 2002. IEEE* Bd. 3 (2002) — ISBN VO - 3
- [SDLC93] SPIEGELHALTER, DJ ; DAWID, AP ; LAURITZEN, SL ; COWELL, RG: Bayesian analysis in expert systems. In: *Statistical science* Bd. 8 (1993), Nr. 3, S. 219–247
- [ShMS15] SHIL, SHUBHASHIS KUMAR ; MOUHOU, MALEK ; SADAOU, SAMIRA: Winner Determination in Multi-attribute Combinatorial Reverse Auctions. In: ARIK, S. ; HUANG, T. ; LAI, W. K. ; LIU, Q. (Hrsg.): *Neural Information Processing*. Cham : Springer International Publishing, 2015 — ISBN 978-3-319-26555-1, S. 645–652
- [SiZi15] SIMONYAN, KAREN ; ZISSERMAN, ANDREW: Very deep convolutional networks for large-scale image recognition. In: *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings* (2015), S. 1–14
- [Skrz11] SKRZYPIETZ, BIGS THERESE: *Die Nutzung von UAS für zivile Aufgaben*, 2011
- [Smir18] SMIRNOV, DENIS: *Ontologiebasierte Modellierung perceptiver Ressourcen an Bord unbemannter Luftfahrzeuge*, Universität der Bundeswehr München, 2018
- [SRKK13] STERN, CLAUDIUS ; RASCHE, CHRISTOPH ; KLEINJOHANN, LISA ; KLEINJOHANN, BERND: *Grundlegende Untersuchungen zur Bildauswertung und Koordinierung für einen Schwarm unbemannter Flugobjekte zur videogestützten Überwachung eines Großunfalls*, 2013
- [SrNM21] SRIVASTAVA, SRISHTI ; NARAYAN, SARTHAK ; MITTAL, SPARSH: A survey of deep learning techniques for vehicle detection from UAV images. In: *Journal of Systems Architecture* Bd. 117, Elsevier B.V. (2021)
- [StBW99] STEINBERG, ALAN N ; BOWMAN, CHRISTOPHER L ; WHITE, FRANKLIN E: Revisions to the JDL data fusion model. In: *AeroSense'99* : International Society for Optics and Photonics, 1999, S. 430–441
- [STWE04] SULLIVAN, DON ; TOTAH, JOSEPH J. ; WEGENER, STEVE S. ; ENOMOTO, FRANCIS Y. ; FROST, CHAD R. ; KANESHIGE, JOHN ; FRANK, JEREMY E.: Intelligent mission management for uninhabited aerial vehicles. In: *Proceedings of the SPIE* Bd. 5661 (2004), S. 121–131
- [TaPL20] TAN, MINGXING ; PANG, RUOMING ; LE, QUOC V.: EfficientDet: Scalable and efficient object detection. In: *Proceedings of the IEEE Computer Society Conference on*

- Computer Vision and Pattern Recognition*, IEEE Computer Society (2020), S. 10778–10787
- [Tapr11] TA-PROJEKT, ENDBERICHT: Stand und Perspektiven der militärischen Nutzung unbemannter Systeme (2011), Nr. 144
- [TaSt17] TANENBAUM, A S ; VAN STEEN, M: *Distributed Systems*: CreateSpace Independent Publishing Platform, 2017 — ISBN 9781543057386
- [TCSS21] TOUVRON, HUGO ; CORD, MATTHIEU ; SABLAYROLLES, ALEXANDRE ; SYNNAEVE, GABRIEL ; JÉGOU, HERVÉ: Going deeper with Image Transformers. In: *Proceedings of the IEEE International Conference on Computer Vision*, Institute of Electrical and Electronics Engineers Inc. (2021), S. 32–42 — ISBN 9781665428125
- [ThBF05] THRUN, SEBASTIAN ; BURGARD, WOLFRAM ; FOX, DIETER: *Probabilistic Robotics (Intelligent Robotics and Autonomous Agents)*: The MIT Press, 2005 — ISBN 0262201623
- [ThRA06] THEODORE, C ; ROWLEY, D ; ANSAR, A: Flight Trials of a Rotorcraft Unmanned Aerial Vehicle Landing Autonomously at Unprepared Sites. In: *Annual Forum Proceedings-American Helicopter Society* Bd. 62 (2006), S. 1250 — ISBN 1552-2938
- [TiLY21] TIAN, GANGYI ; LIU, JIANRAN ; YANG, WENYUAN: A dual neural network for object detection in UAV images. In: *Neurocomputing* Bd. 443, Elsevier B.V. (2021), S. 292–301
- [Tofa14] TOFALLIS, CHRIS: Add or multiply? A tutorial on ranking and choosing with multiple criteria. In: *INFORMS Transactions on education* Bd. 14, INFORMS (2014), Nr. 3, S. 109–119
- [ToHo13] TOKEKAR, PRATAP ; HOOK, JV: Sensor Planning for a Symbiotic UAV and UGV system for Precision Agriculture. In: *Intelligent Robots and Systems (IROS)*, 2013
- [ToWu22] TONG, KANG ; WU, YIQUAN: Deep learning-based detection from the perspective of small or tiny objects: A survey. In: *Image and Vision Computing* Bd. 123 (2022), S. 104471
- [TRZX06] TISDALE, JOHN ; RYAN, ALLISON ; ZENNARO, MARCO ; XIAO, XIAO ; CAVENEY, DEREK ; RATHINAM, SIVA ; HEDRICK, J. KARL ; SENGUPTA, RAJA: The software architecture of the berkeley UAV platform. In: *Proceedings of the IEEE International Conference on Control Applications* (2006), S. 1420–1425 — ISBN 0780397959
- [Uhrm12] UHRMANN, JOHANN: *Auftragsbasierte Multi-UAV-Führung aus dem Helikoptercockpit durch kognitive Automation*, 2012
- [UhSc12] UHRMANN, JOHANN ; SCHULTE, AXEL: Concept , Design and Evaluation of Cognitive Task-based UAV Guidance Bd. 5 (2012), Nr. 1
- [Vach15] VACHTSEVANOS, GEORGE J ; VALAVANIS, K. P. ; VACHTSEVANOS, G. J. (Hrsg.): *Handbook of Unmanned Aerial Vehicles*. Dordrecht : Springer Netherlands, 2015 — ISBN 978-90-481-9706-4

- [VaMe21] VALAPPIL, NAJIYA K. ; MEMON, QURBAN A.: CNN-SVM based vehicle detection for UAV platform. In: *International Journal of Hybrid Intelligent Systems* Bd. 17, IOS Press (2021), Nr. 1–2, S. 59–70
- [Vans10] VANSCHOREN, JOAQUIN: *Understanding Machine Learning Performance with Experiment Databases*, 2010
- [ViKe09] VIOLLET, STEPHANE ; KERHUEL, LUBIN: A vision-based steering control system for aerial vehicles. In: *Aerial Vehicles*, 2009, S. 653–670
- [VSPU17] VASWANI, ASHISH ; SHAZEER, NOAM ; PARMAR, NIKI ; USZKOREIT, JAKOB ; JONES, LLION ; GOMEZ, AIDAN N ; KAISER, ŁUKASZ ; POLOSUKHIN, ILLIA: Attention is All you Need. In: GUYON, I. ; LUXBURG, U. VON ; BENGIO, S. ; WALLACH, H. ; FERGUS, R. ; VISHWANATHAN, S. ; GARNETT, R. (Hrsg.): *Advances in Neural Information Processing Systems*. Bd. 30 : Curran Associates, Inc., 2017
- [WaBL21] WANG, CHIEN-YAO ; BOCHKOVSKIY, ALEXEY ; LIAO, HONG-YUAN MARK: Scaled-YOLOv4: Scaling Cross Stage Partial Network (2021)
- [WaBL22] WANG, CHIEN-YAO ; BOCHKOVSKIY, ALEXEY ; LIAO, HONG-YUAN MARK: YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors (2022)
- [WaCJ07] WATANABE, YOKO ; CALISE, ANTHONY J ; JOHNSON, ERIC N: Vision-Based Obstacle Avoidance for UAVs. In: *Update* (2007), Nr. August, S. 1–11 — ISBN 1563479044
- [WaJo08] WAINWRIGHT, MARTIN J ; JORDAN, MICHAEL IRWIN: *Graphical models, exponential families, and variational inference* : Now Publishers Inc, 2008
- [Wang11] WANG, CHAU-CHANG: *Laser Scanning: Theory and Applications*, 2011 — ISBN 9789533072050
- [WeBi95] WELCH, GREG ; BISHOP, GARY: An introduction to the Kalman filter (1995)
- [Welc14] WELCHOWSKI, THOMAS: *Statistische Modellierung latenter Strukturen in den Lebens-, Sozial- und Wirtschaftswissenschaften*, Ludwig-Maximilians-Universität München, 2014
- [Weng10] WENG, QIHAO: *Remote sensing and GIS integration - theories, methods and applications*, 2010 — ISBN 9780071606547
- [Weze07] WEZEMAN, SIEMON: *UAVs and UCAVs: Developments in the European Union*, 2007
- [WiHW12] WINNER, HERMANN ; HAKULI, STEPHAN ; WOLF, GABRIELE: *Handbuch Fahrerassistenzsysteme: Grundlagen, Komponenten und Systeme für aktive Sicherheit und Komfort*, 2012 — ISBN 9783834802873
- [Will07] WILLIAMS, JASON L: *Information Theoretic Sensor Management*, 2007

- [WiMu17] WINDARTO, AGUS ; MUHAMMAD, ABULWAFI: Comparison of Weighted Sum Model and Multi Attribute Decision Making Weighted Product Methods in Selecting the Best Elementary School in Indonesia. In: *International Journal of Software Engineering and Its Applications* Bd. 11 (2017), S. 69–90
- [WLHT21] WU, XIN ; LI, WEI ; HONG, DANFENG ; TAO, RAN ; DU, QIAN: Deep Learning for UAV-based Object Detection and Tracking: A Survey. In: *IEEE Geoscience and Remote Sensing Magazine* Bd. 10, Institute of Electrical and Electronics Engineers Inc. (2021), Nr. 1, S. 91–124 — ISBN 2021M690385
- [WoBl07] WOHLERS, KLAUS ; BLOHM, CHRISTIAN: Führungskonzept der KZO Drohne Autonomie und Verantwortlichkeiten. In: *Workshop der DGLR Fachausschüsse*. Neubiberg, 2007
- [WRRG07a] WALLHOFF, F ; RUSS, M ; RIGOLL, G ; GÖBEL, JOHANN ; HERMANN, DIEHL: Improved image segmentation using photonic mixer devices. In: *Image Processing, ...*, 2007
- [WRRG07b] WALLHOFF, F ; RUSS, M ; RIGOLL, G ; GÖBEL, JOHANN ; HERMANN, DIEHL: Surveillance and activity recognition with depth information. In: *Multimedia and Expo, ...*, 2007, S. 3–6
- [WTSG09] WHALLEY, MATTHEW ; TAKAHASHI, MARC ; SCHULEIN, GREGORY J. ; GOERZEN, CHAD: Field-testing of a helicopter UAV obstacle field navigation and landing system. In: *AHS Annual Forum* (2009)
- [XiSv02] XIONG, N ; SVENSSON, P: Multi-sensor management for information fusion : issues and approaches Bd. 3 (2002), S. 163–186
- [XWYY22] XU, CHANG ; WANG, JINWANG ; YANG, WEN ; YU, HUAI ; YU, LEI ; XIA, GUI-SONG: Detecting tiny objects in aerial images: A normalized Wasserstein distance and a new benchmark. In: *{ISPRS} Journal of Photogrammetry and Remote Sensing* Bd. 190, Elsevier {BV} (2022), S. 79–93
- [YaLi08] YAGER, R R ; LIU, L: *Classic Works of the Dempster-Shafer Theory of Belief Functions, Studies in Fuzziness and Soft Computing* : Springer Berlin Heidelberg, 2008 — ISBN 9783540447924
- [ZCSG23] ZOU, ZHENGXIA ; CHEN, KEYAN ; SHI, ZHENWEI ; GUO, YUHONG ; YE, JIEPING: Object Detection in 20 Years: A Survey. In: *Proceedings of the IEEE* Bd. 111, IEEE (2023), Nr. 3, S. 257–276
- [ZhPi13] ZHANG, QIN ; PIERCE, FRANCIS J: *Agricultural Automation Fundamentals and Practices*, 2013 — ISBN 9781439880586



