Motius Abschlussbericht

5G Lab für Künstliche Intelligenz

Im Verbundprojekt

FunKI

Funkkommunikation mit Künstlicher Intelligenz

Laufzeit des Vorhabens:	**15.05.2020 - 14.11.2023**
Förderkennzeichen:	**16KIS1183**

Motius GmbH
Walter-Gropius-Str 17
D-80807 München

Ansprechpartner:
Alberto Viseras alberto.viseras@motius.de +49 176 9775 8305

1 Beschreibung der Arbeitspakete des Projekts

1.1 AP 1: Projektkoordination und -Kommunikation, Anwendungsfälle und Szenarien

Motius unterstützte bei der Aktualisierung der Website-Elemente, welche Partnerbeschreibungen und eine Liste projektbezogener Veröffentlichungen umfassten. Motius nahm regelmäßig an Konsortialsitzungen für die verschiedenen Arbeitspakete teil und führte einen Online-Workshop zur Einführung der Projektpartner in die Grundlagen von GNU-Radio durch. Zusammen mit Creonic wurde ein Präsenztreffen organisiert, um die Roadmap und die nächsten Schritte für den Aufbau eines Demonstrators im AP 5 zu diskutieren. Zudem präsentierte Florian Geiser vom Motius-Team die Arbeit auf der SFSCon-Konferenz. In den Anwendungsfällen und Szenarien definierte Motius industrierelevante Use Case Gruppen und Beispiele sowie die entsprechenden Service-Level-Anforderungen und KPIs in Zusammenarbeit mit den verantwortlichen Partnern.

1.2 AP 2: Sende- und Empfängerstrukturen

Motius hat spezialisierte Verarbeitungsblöcke für die iterative Signaldetektion (MIMO, Entzerrung) und Decodierung zu einem eingelernten Block (DNN, RNN, CNN) mit reduzierter Latenz zusammengelegt. Verschiedene ML-Ansätze wurden analysiert, um die drahtlose Kommunikation in Fahrzeugumgebungen zu verbessern. Der Einsatz von Deep Learning zur Synchronisierung und Signalerfassung für IEEE 802.11p wurde vorgeschlagen und die Ergebnisse in einer Masterarbeit veröffentlicht. Für die MIMO-Kanalschätzung und -entzerrung wurden nach Literaturrecherche neuronale Netzarchitekturen ausgewählt, implementiert und mit Nokia-Kanalmessungen sowie klassischen Modellen bewertet. MIMO-OFDM-Systeme wurden durch modifizierte GNU-Radio-Pipelines angepasst, um neuronale Netze zu integrieren. Zudem wurden geeignete ML-Verfahren für die Signalverarbeitungskette von Mehrträgermodulationsverfahren untersucht und mehrere Netzarchitekturen hinsichtlich Leistung und Ressourcenbedarf verglichen.

1.3 AP 3: Kanaladaption

Motius hat einen Deep Reinforcement Learning (DRL)-Ansatz zur Link-Adaption implementiert und evaluiert. Zwei state-of-the-art actor-critic DRL-Algorithmen wurden entwickelt, um den Durchsatz zu optimieren, und auf simulierten sowie voraufgezeichneten realen Kanälen getestet. Für die Kanalparameterschätzung wurden vielversprechende Deep-Learning-Modelle, insbesondere Entrausch- und Superresolution-Architekturen, verwendet. Die Trainings- und Evaluierungspipelines wurden entwickelt, das Training der neuronalen Netze sowie die Optimierung der Hyperparameter erfolgreich abgeschlossen. Methoden zur Verkehrsklassifizierung auf OFDM 802.11p-Wellenformen mit einem Deep Convolutional Neural Network erreichten eine Genauigkeit von 90 % und zeigten sich robust über einen breiten Bereich von SNRs, einschließlich Fading- und entzerrter Fading-Kanalfälle.

1.4 AP 4: Effiziente Implementierung von Transceivern

Die Motius GmbH ist nicht direkt an den Arbeiten in AP4 beteiligt.

1.5 AP 5: SDR Demonstrator

Motius hat in Zusammenarbeit mit *Creonic* und den Projektpartnern geeignete Demonstrationsszenarien festgelegt, insbesondere für die Demonstration der Kanalschätzung mittels KI unter dem Namen “Refined Least Square Channel Estimation”. Die Schnittstellen wurden gemeinsam mit Creonic definiert, und eine Pipeline zur Testung und Bewertung des Algorithmus wurde entwickelt. Diese Pipeline wurde an Creonic übergeben, um das neuronale Netz auf dem FPGA zu implementieren. Unter den Netzwerkkandidaten wurde sich auf ein finales CNN festgelegt, welches im Anschluss von *Creonic* synthetisiert wurde. Die Größe des Netzwerkes, insbesondere in den Input-Layern, überschritt hierbei die Größe des eingesetzten FPGA, sodass hierbei leider kein Messedemonstrator präsentiert werden konnte.

2 Wissenschaftlich-technische Ergebnisse

2.1 Deep Reinforcement Learning for Link Adaptation on the Edge

Link Adaptation (LA) spielt eine entscheidende Rolle in der Telekommunikation und ist ein wichtiger Aspekt für die nächste Generation mobiler Kommunikationssysteme. Durch die Verfeinerung der LA kann die Kanaleffizienz gesteigert werden, was eine höhere Datenrate bei gleichzeitig reduziertem Bandbreitenbedarf zur Folge hat. Traditionelle Algorithmen zur Link Adaptation stoßen jedoch auf verschiedene Herausforderungen, da sie oft auf vordefinierten und statischen Entscheidungsgrenzen oder auf niedrigdimensionalen Metriken basieren. Im Gegensatz dazu kann ein neuronales Netzwerk mehrere Parameter als Eingabe verarbeiten und Entscheidungsgrenzen erzeugen, die komplexere Parameterbeziehungen berücksichtigen. Daher untersucht dieses Projekt das Potenzial von Deep Reinforcement Learning (DRL) für die LA und führt Experimente durch, um notwendige nächste Schritte für die zukünftige Integration in mobile Telekommunikationssysteme zu identifizieren.

In dieser Arbeit wurde ein DRL-Algorithmus entwickelt, der in der Lage ist, auf verschiedenen Kanälen, einschließlich eines aufgezeichneten realen Kanals, zu operieren. Die Ergebnisse zeigen, dass der DRL-Ansatz besonders gut auf dem Additive White Gaussian Noise (AWGN)-Kanal funktioniert, während die Grenzen auf dem realen Kanal deutlich werden. Trotzdem ist der Agent in der Lage, auf wechselnde SNR-Niveaus zu reagieren, was sich in erwarteten Änderungen der effektiven Datenrate zeigt.

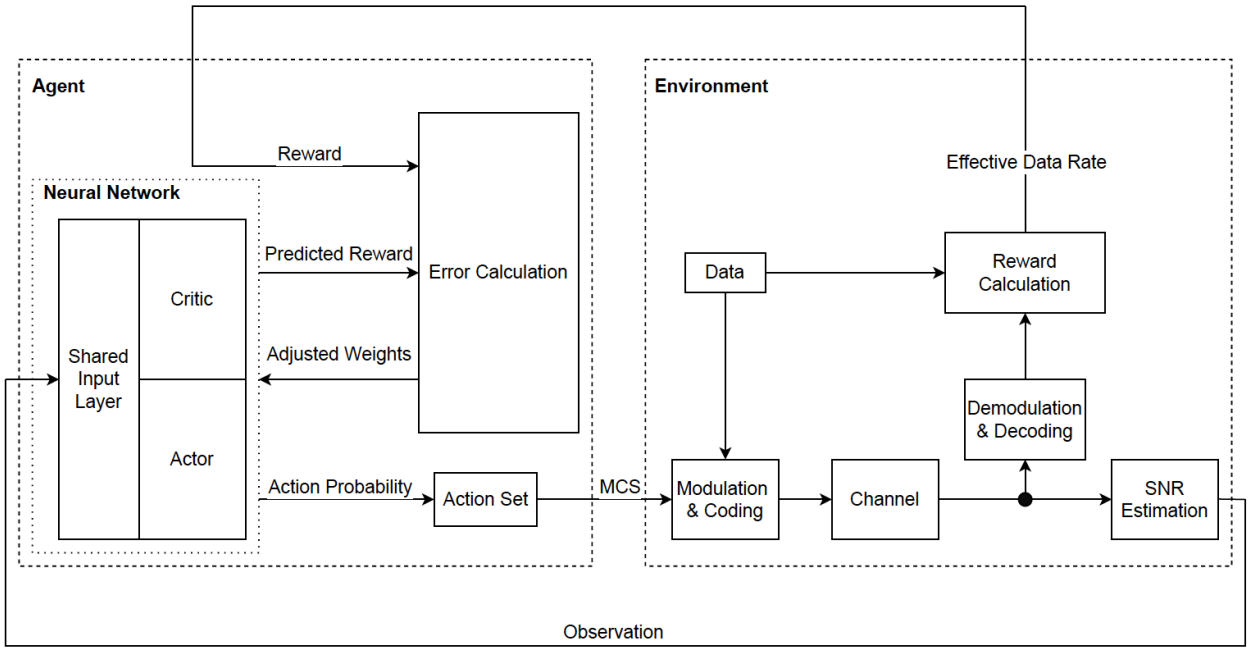

Figure 1 Actor-Critic Verstärkungslernansatz mit verwendeten Werkzeugen.

Das Ziel der Link Adaptation besteht darin, geeignete Modulations- und Codierungsschemata für eine Datenübertragung zu finden, die die Qualität der Funkverbindung berücksichtigen. Der traditionelle Ansatz, wie das Outer Loop Link Adaptation (OLLA), verwendet einfache Entscheidungsmechanismen auf Basis von SINR-Werten, die als robuste, aber niedrigdimensionale Stellvertreter dienen. Im Gegensatz dazu schlägt diese Arbeit einen DRL-Algorithmus vor, der mehrere Zustände, die Umgebung und die physikalischen Eigenschaften eines drahtlosen Übertragungssystems berücksichtigt. Dies führt zu einer dynamischeren und anpassungsfähigeren Lösung.

Zur Bewertung der vorgeschlagenen Vision einer Edge-Implementierung wurde ein Algorithmus-Instanz lokal ausgeführt. Dabei wurde DRLLA (Deep Reinforcement Learning for Link Adaptation) unter Verwendung von

OpenAI Gym und einer integrierten GNU Radio-Simulationsumgebung implementiert. Verschiedene Kanäle, wie AWGN, Non-Line-of-Sight (NLOS) und ein realer Kanal, wurden genutzt, um die Leistung des Ansatzes zu prüfen. Die Ergebnisse zeigen, dass der DRL-Ansatz besonders auf dem AWGN-Kanal eine hohe Effektivität erreicht, während die Leistungsfähigkeit auf dem realen Kanal begrenzt ist.

Die Ergebnisse der Experimente auf dem AWGN-Kanal zeigen, dass der Agent nach einigen Trainingsdurchläufen in der Lage ist, das optimale Modulations- und Codierungsschema (MCS) zu identifizieren, was zu einer hohen effektiven Datenrate führt. Auf dem NLOS-Kanal, der zusätzlich zu AWGN eine Rayleigh-Fading-Modellierung und eine 3GPP-konforme V2X-Dämpfung nutzt, zeigt der Agent ebenfalls eine gute Anpassungsfähigkeit, wobei eine Kombination aus verschiedenen MCS verwendet wird, um die bestmögliche Datenrate zu erzielen.

Die realen Kanäle zeigen jedoch die Grenzen des aktuellen DRL-Ansatzes auf. Trotz der Fähigkeit des Agents, auf Veränderungen im SNR zu reagieren, bleibt die effektive Datenrate deutlich hinter der theoretisch möglichen Rate zurück. Dies deutet darauf hin, dass die realen Kanaleffekte, die in den voraufgezeichneten Kanaldaten enthalten sind, zu einer höheren Paketfehlerrate (PER) führen.

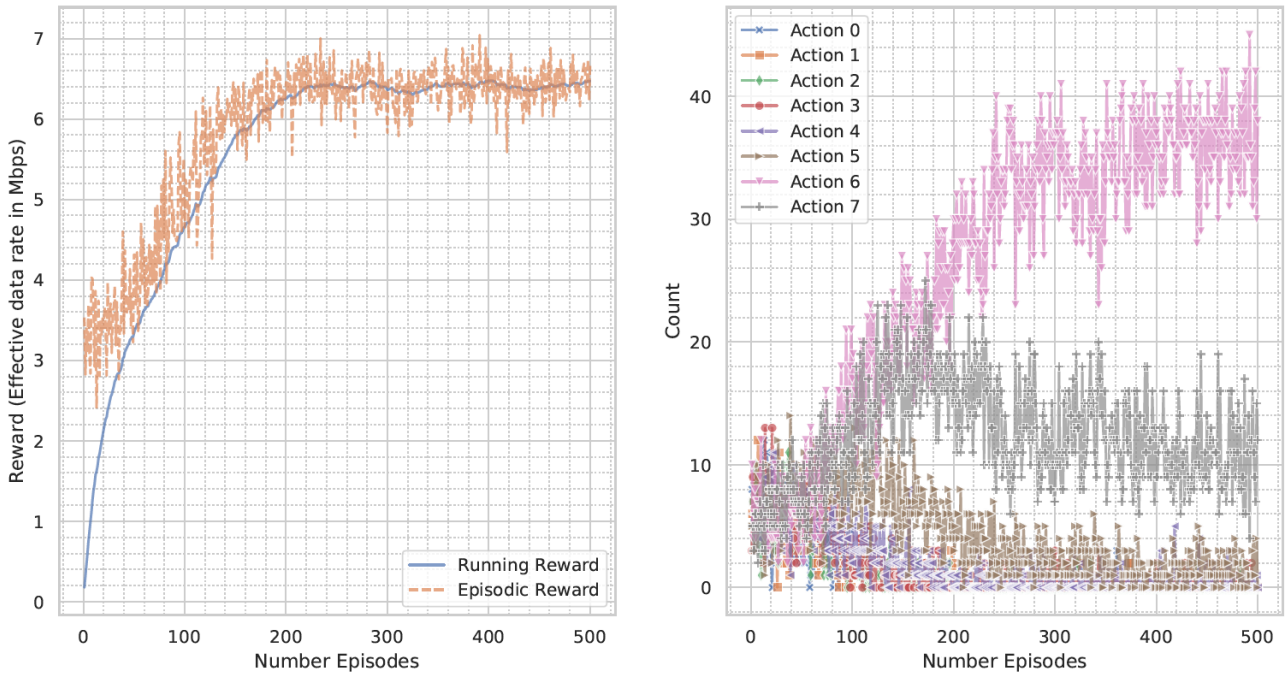

Figure 2 Verhalten eines NAC-Verstärkungslernansatzes auf einem realen Kanal bei einem statischen SNR von 15 dB.

Abschließend lässt sich festhalten, dass der vorgestellte DRL-Ansatz für die Link Adaptation ein vielversprechender Schritt in Richtung dynamischer und anpassungsfähiger Telekommunikationssysteme ist. Zukünftige Arbeiten sollten sich darauf konzentrieren, die Belohnungsfunktion anzupassen, um zusätzliche Merkmale des Übertragungssystems zu berücksichtigen, und die Beobachtungsräume zu erweitern, um die Entscheidungsfindung des Agents weiter zu verbessern. Ein weiterer wichtiger Schritt wäre die Implementierung des Ansatzes in realen 4G- oder 5G-Netzwerken, um die Praxistauglichkeit und Effizienz des DRL-Ansatzes umfassend zu validieren.

2.2 A Comparative Study of Least Squares Refinement Methods for IEEE 802.11p Channel Estimation

Kanalabschätzung ist entscheidend, um die Kanalzustandsinformationen (CSI) in drahtlosen Kommunikationssystemen zu erhalten. Diese Information wird genutzt, um den empfangenen Datenstrom zu entzerren und die ursprünglich gesendete Nachricht zu rekonstruieren. Traditionelle Ansätze, wie der Least Squares (LS) Schätzer, sind zwar einfach und haben eine geringe Komplexität, leiden jedoch unter hoher Rauschanfälligkeit, was zu höheren Schätzfehlern bei niedrigen Signal-Rausch-Verhältnissen (SNR) führt.

Der Minimum Mean Square Error (MMSE) Schätzer berücksichtigt hingegen Informationen über den Kanal und die Rauschvarianz und bietet eine bessere Leistung. Allerdings ist dieser komplex zu berechnen und erfordert, dass der Empfänger bestimmte Eigenschaften des Kanals während der Schätzung kennt, was in realen Szenarien oft nicht realistisch ist. Praktische Annäherungen an den MMSE Schätzer reduzieren den notwendigen a priori Wissensstand über den Kanal, sind aber dennoch rechnerisch aufwändig.

In den letzten Jahren haben maschinelles Lernen (ML) und insbesondere Deep Learning (DL) großes Interesse im Bereich der Kommunikation geweckt. Ein Forschungsansatz besteht darin, die gesamte Kommunikationspipeline durch ML-basierte Methoden zu ersetzen. Diese Ansätze zeigen vielversprechende Ergebnisse, stoßen jedoch auf Herausforderungen beim Lernen über den nicht-differenzierbaren Kommunikationskanal. Eine alternative Gruppe von Ansätzen untersucht die Verbesserung konventioneller Algorithmen durch ML-basierte Methoden.

Ein vielversprechender Ansatz zur Verfeinerung der LS-Schätzung (LS+) setzt auf künstliche neuronale Netzwerke (NN). Diese Ansätze behandeln die LS-Schätzung des Kanals als niedrigauflösende Eingabe und zielen darauf ab, eine hochauflösende Schätzung des Kanals zu reproduzieren. Trotz zahlreicher Arbeiten, die verschiedene NN-basierte LS+ Methoden untersuchen, vergleichen diese Arbeiten ihre Ergebnisse oft nur mit einer begrenzten Anzahl konventioneller Baselines und werten die Ansätze nicht auf realen Daten aus.

Diese Arbeit führt eine umfassende Vergleichsstudie durch und bewertet verschiedene Implementierungsaspekte von LS+ Methoden anhand realer Kanalmessungen. Die wichtigsten Erkenntnisse dieser Studie sind:

1. Dies ist die erste Arbeit, die LS+ Methoden auf realen Kanalaufzeichnungen evaluiert und sie mit konventionellen Kanalabschätzungsverfahren vergleicht.
2. Der Einfluss verschiedener Trainings-SNR-Bereiche auf die Generalisierbarkeit des Modells wird untersucht.
3. Fünf verschiedene Methoden zur Umwandlung komplexer in reale Zahlen und deren Einfluss auf die Modellleistung und -komplexität werden evaluiert.

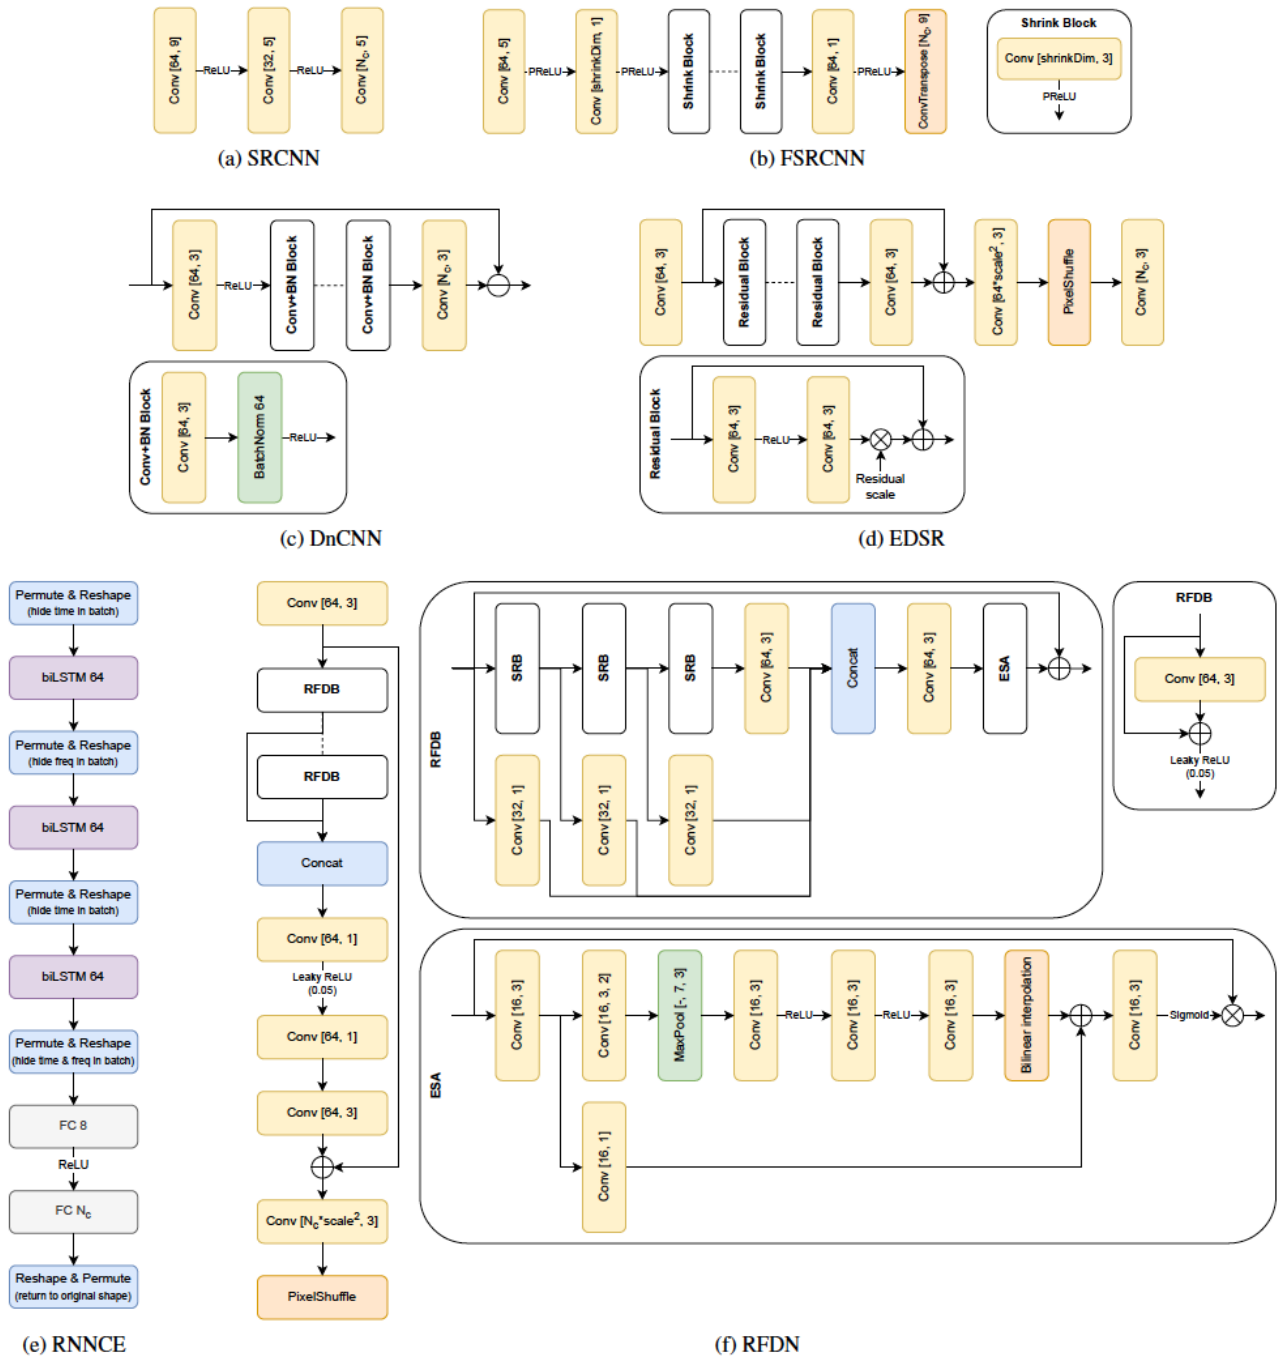

Figure 3 Modellarchitekturen und Submodule, die in dieser Arbeit berücksichtigt wurden. Jeder Block stellt ein Modul dar, wobei das Blocklabel "{Blockname} [Anzahl der Merkmale]" lautet.

Die Studie zeigt, dass Modelle, die auf einem weiten SNR-Bereich trainiert wurden, sowohl bei niedrigen als auch bei hohen SNR-Werten gute Leistungen erbringen. Im Vergleich zu konventionellen Baselines erreichen einige der besten Modelle eine ähnliche oder sogar bessere Leistung als der blockbasierte LMMSE Schätzer, was auf eine signifikante Verbesserung gegenüber dem comb-basierten LS Schätzer hinweist, der als Eingang für die Verfeinerungsmodelle in den NN-basierten LS+ Ansätzen dient.

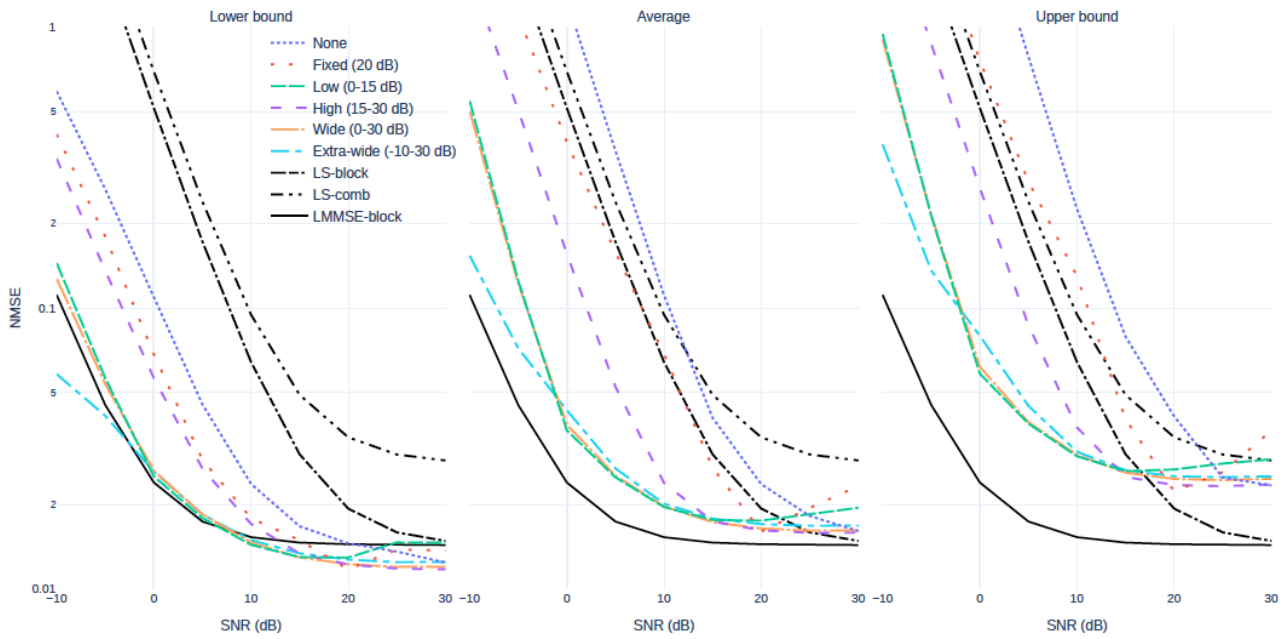

Figure 4 Ergebnisse für verschiedene Trainingsrauschpegel auf dem langsamen Datensatz unter Verwendung von Channel-C2R und Comb-Piloteninformationen, aggregiert über alle neuronalen Netzwerkarchitekturen.

Die Experimente zeigen auch, dass die Methode zur Umwandlung komplexer in reale Zahlen (C2R) einen Einfluss auf die Modellleistung hat. Von den getesteten Ansätzen zeigte die Kanal-C2R-Methode durchgehend die beste Leistung. Diese Methode erweist sich auch als stabiler und effizienter in Bezug auf Rechenaufwand und Laufzeit.

Ein weiterer wichtiger Punkt ist die Anordnung der Piloten. Modelle, die sowohl auf block- als auch auf comb-basierte Piloten zugreifen, übertreffen alle anderen Ansätze signifikant. Dies gilt insbesondere in Szenarien mit hohen Geschwindigkeiten, bei denen die Kanalstationarität abnimmt.

Insgesamt zeigen die Ergebnisse, dass moderne, komplexere Netzwerkarchitekturen in der Lage sind, besser zu generalisieren und konventionelle Methoden deutlich zu übertreffen. Die Studie legt nahe, dass für die Entwicklung von NN-basierten LS+ Schätzern ein breiter SNR-Bereich, die Kanal-C2R-Methode und eine Kombination aus block- und comb-basierten Piloten verwendet werden sollten.

2.3 Traffic Classification on OFDM 802.11p Waveforms using a Deep Convolutional Neural Network

Die Verkehrsklassifizierung (Traffic Classification, TC) beinhaltet die Analyse von Netzwerkdaten zur Bestimmung der entsprechenden Verkehrsklasse, wie z.B. YouTube, HTTP, Streaming oder Malware. Diese Klassifizierung kann in verschiedenen Anwendungsfällen genutzt werden, wie z.B. im Traffic Management zur Qualitätssicherung (QoS) oder in der Netzwerksicherheit. Traditionelle Methoden zur Verkehrsklassifizierung umfassen portbasierte Ansätze, Deep Packet Inspection (DPI) und maschinelles Lernen. Besonders vorteilhaft ist die Anwendung der Verkehrsklassifizierung auf der physikalischen Ebene in drahtlosen Kommunikationsszenarien, wie dem Vehicle-to-Everything (V2X).

Im Jahr 2022 wurde eine allgemeine Methode zur Verkehrsklassifizierung in drahtlosen Netzwerken unter Verwendung von Deep Learning vorgestellt, die eine Genauigkeit von 92% bei Signal-Rausch-Verhältnissen (SNR) zwischen 20dB und 30dB erreichte. In der aktuellen Arbeit wurde ein tiefes konvolutionales neuronales Netzwerk (CNN) adaptiert, um vier Verkehrsklassen (YouTube, Vimeo, Cooperative Automotive Messages (CAM) und keine Anwendung) auf OFDM 802.11p Wellenformen zu klassifizieren, auch bei niedrigeren SNRs und in fading-Kanälen.

Zur Datensatzgenerierung wurde Wireshark verwendet, um Layer-2-Netzwerkverkehr zu erfassen und anhand von Ports zu labeln. Der Datensatz umfasste 10.000 Trainingsproben, 2000 Validierungsproben und 1000 Testproben pro Anwendung, wobei CAM die Hälfte der Proben umfasste. Die OFDM 802.11p Wellenformen wurden mit einem 16 QAM Modulationsschema, 64 Unterträgern und einer zyklischen Präfixlänge von 16 generiert, um Inter-Symbol-Interferenzen (ISI) zu vermeiden.

Für die Kanalmodellierung wurden vier Szenarien evaluiert: idealer Kanal, AWGN (Additive White Gaussian Noise), fading Kanal und equalized fading Kanal, bei SNRs von -5dB bis 20dB. Der CNN wurde mit einer Kreuzentropie-Verlustfunktion und einem Softmax-Ausgang angepasst, um Überanpassungen zu vermeiden. Die Ergebnisse zeigten, dass das Modell in allen Szenarien eine Genauigkeit von rund 90% erreichte und die Vorhersagen über alle SNRs hinweg robust waren.

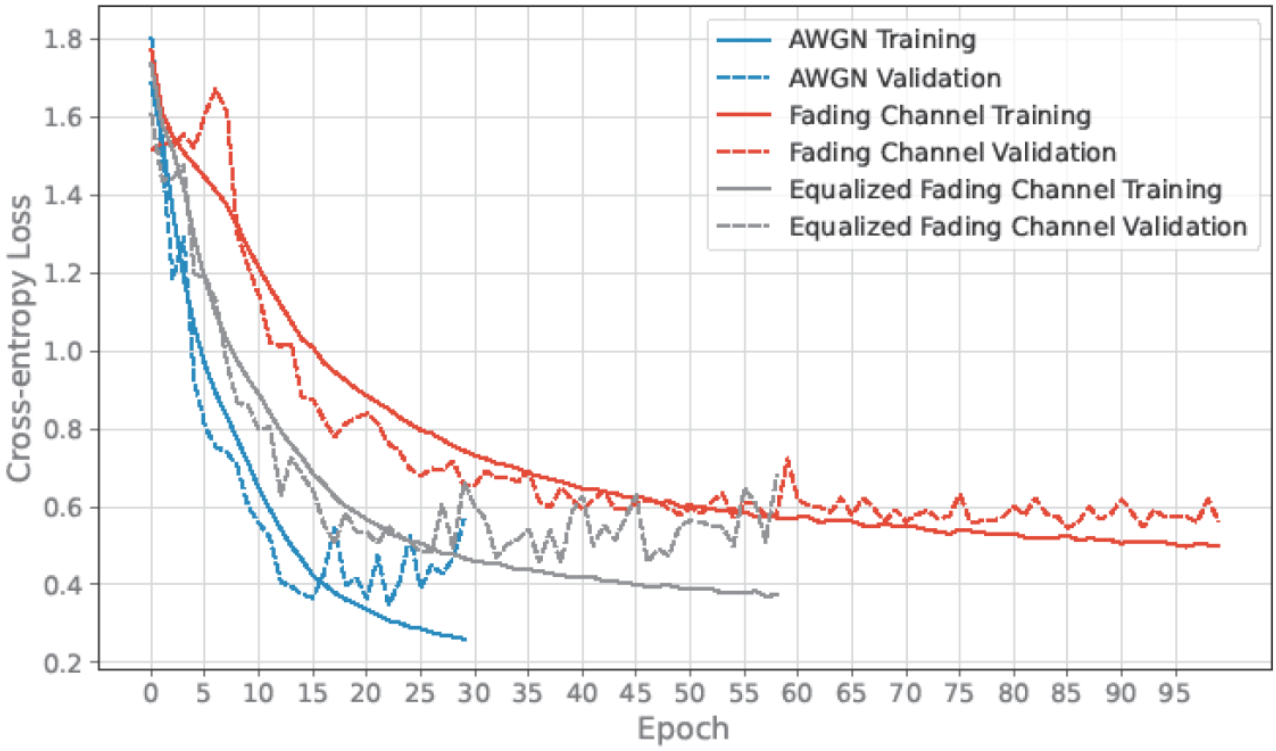

Figure 5 Fading-Kanal und equalisierter Fading-Kanal.

Schließlich wurden Ansätze für zukünftige Arbeiten diskutiert, wie die Untersuchung der Modellverhaltensweise, die Anwendung der Verkehrsklassifizierung auf realen Wellenformen, die Erstellung diverser Datensätze und die Überarbeitung des CNNs, um mehr Anwendungen abzudecken.

2.4 Synchronization and Signal Detection in Wireless Communications: A Deep Learning Approach

Die drahtlose Kommunikation hat zu Beginn des 21. Jahrhunderts dank der hocheffizienten Fast Fourier Transform (FFT) basierten Orthogonal Frequency Division Multiplexing (OFDM) einen bedeutenden Fortschritt gemacht, der in der Lage ist, den Mehrwege-Fading-Kanal zu bekämpfen. Der auf OFDM basierende 2. Generation Wi-Fi™-Standard, definiert durch das Institute of Electrical and Electronics Engineers (IEEE) 802.11a Wireless Local Area Network (WLAN), ermöglichte eine fünffache Steigerung der Datenraten im Vergleich zur ersten Generation von Wi-Fi™. Heute wird der gleiche drahtlose Standard, geändert als IEEE 802.11p, in der Dedicated Short Range Communications (DSRC) für die drahtlose Kommunikation in Fahrzeugumgebungen (WAVE) verwendet, die für autonomes Fahren und

Sicherheitsanwendungen im Fahrzeugverkehr vorgesehen sind. Da der ursprüngliche Standard für Heim- und Büroumgebungen mit niedriger Mobilität, d.h. quasi-stationären Kanalbedingungen, ausgelegt war, versagen die bestehenden Algorithmen zur digitalen Signalverarbeitung (DSP) am Empfängerende bei der Synchronisation, Kanalschätzung, Entzerrung und Detektion unter den hochmobilen, d.h. stark variierenden Kanalbedingungen, denen ein Fahrzeug typischerweise in städtischen und vorstädtischen Umgebungen begegnet.

Diese stark variierenden Kanalbedingungen zwingen uns zur Entwicklung von DSP-Algorithmen, die breite Variationen bewältigen können. In den letzten Jahren wurden erhebliche Anstrengungen unternommen, um die Kanalbedingungen für die Mobilität zu messen und zu beschreiben, um spezifische Algorithmen zu entwickeln und zu evaluieren, die mit der hochsporadischen Natur dieser Kanalbedingungen umgehen können, und so sicherzustellen, dass sicherheitskritische Daten mit sehr geringer Latenz gesendet werden können. Mit mehr Fahrzeugen auf der Straße werden höherwertige Modulations- und Kodierungsschemata (MCS) auf der physikalischen Schicht (PHY) viel häufiger erforderlich sein, um längere Datenpakete für nicht sicherheitskritische Anwendungen wie lokale Kartendaten auszutauschen. Wie bereits erwähnt, versagen die konventionellen DSP-Algorithmen am Empfängerende dabei, diese beiden Hauptanforderungen gleichzeitig zu erfüllen, nämlich (i) sehr geringe Latenz, die eine niedrige Rechenkomplexität erfordert, und (ii) Robustheit gegenüber stark variierenden Kanalbedingungen, die die Berücksichtigung der Kanalbedingungen erfordert. Es gibt bereits zahlreiche Algorithmen, die eine dieser beiden Bedingungen auf Kosten der anderen erfüllen. Es ist auch nicht realisierbar, einen Signalverarbeitungsalgorithmus zu entwickeln, der alle möglichen Kanalbedingungen berücksichtigen kann, denen ein Fahrzeug auf der Straße begegnen könnte. Dieser letzte Punkt führt uns dazu, Alternativen im Bereich des Deep Learning (DL) zu suchen, wo wir Modelle entwickeln können, die in der Lage sind, die zugrunde liegende Statistik eines stark zeitvariierenden Kanals zu lernen und das beeinträchtigte Signal erfolgreich wiederherzustellen.

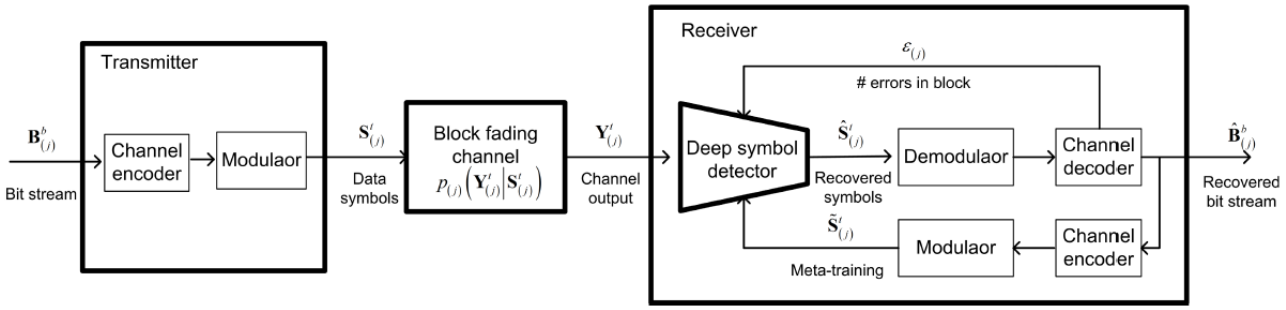

Figure 6 ViterbiNet: DL-basierte Log-Likelihood-Berechnung und Online-Training.

DL hat vielversprechende Anwendungen in zahlreichen Computer Vision (CV)-Problemen gezeigt, wie z.B. Objekterkennung und Gesichtserkennung. Über CV hinaus kann und hat die drahtlose Kommunikation erheblich von DL im Kontext von OFDM profitiert, um das Synchronisationsproblem, das allgemein als Paketerkennung bezeichnet wird, Kanalschätzung und Entzerrung sowie Soft-Signaldetektion zu lösen, die die wesentlichen ersten Schritte bei der Wiederherstellung eines drahtlosen Signals sind. Versuche, ein einzelnes neuronales Netzwerk (NN) zur gemeinsamen Kanalschätzung, Entzerrung und Detektion zu verwenden, haben ebenfalls großartige Ergebnisse für das Pilot-Schema der fünften Generation drahtloser Kommunikation (5G) gezeigt, bei dem der vorgeschlagene neuronale Empfänger den Kanal ohne die Notwendigkeit eines zyklischen Präfixes (CP) sowie Piloten schätzen kann. Neueste DL-Arbeiten für Einkanal-Kurzpaket-Kommunikationssysteme haben gezeigt, wie eine Convolutional Neural Network (CNN)-Architektur nicht nur zur Synchronisation, Entzerrung und Detektion, sondern auch zur Dekodierung verwendet werden kann. Es wurde auch gezeigt, dass ein Deep Autoencoder die gesamte Sender- und Empfängerkette ersetzen kann. Bisher wurden keine Studien durchgeführt, um die Anwendung von DL sowohl für die Synchronisation als auch für die Signaldetektion unter realistischen gemessenen Fahrzeugkanalbedingungen zu bewerten. In dieser Arbeit zielen wir darauf ab, diese Lücke zu schließen, indem wir die bestehenden DL-Modelle, die für die Aufgaben der Synchronisation und Signaldetektion

entwickelt wurden, trainieren. Wir evaluieren dann deren Vorteile sowie deren Nachteile im Vergleich zu den konventionellen Ansätzen. Insbesondere untersuchen wir die Trainingskomplexität und die Rechenkomplexität der Modelle während der Laufzeit im Vergleich zu den konventionellen Methoden.

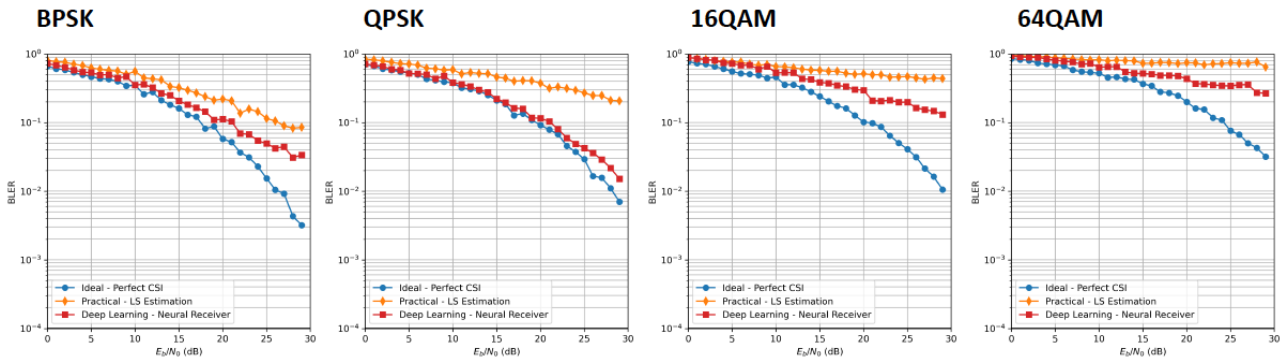

Figure 7 Signaldetektion unter gemessenem Kanalmodell.

Es ist erwähnenswert, dass theoretische Leistungsgrenzen nur für leicht charakterisierbare Kanalumgebungen wie AWGN und Rayleigh-Fading existieren. Alle anderen Kanalumgebungen, einschließlich der in dieser Arbeit behandelten, erfordern eine genaue Simulation. Daher haben wir auch eine vollständige PHY Tx-Rx-Kette entwickelt, um die Auswirkungen von unvollständiger Synchronisation auf die Signaldetektion zu simulieren, was die meisten früheren Arbeiten vernachlässigt haben, indem sie perfekte Synchronisation angenommen haben, was keine sehr realistische Annahme ist, insbesondere bei sicherheitskritischen Anwendungen, bei denen unvollständige Synchronisation dazu führen kann, dass das Paket nicht dekodiert werden kann und daher zusätzliche Verzögerungen durch erneute Übertragung einführt, was aufgrund der kurzen Reichweite möglicherweise nicht mehr möglich ist.

3 Veröffentlichungen

Tabelle 1:

Wissenschaftliche Publikationen
- *DRLLA: Deep Reinforcement Learning for Link Adaption*. Florian Geiser, Daniel Wessel, Matthias Hummert, Andreas Weber, Dirk Wübben, Armin Dekorsy, and Alberto Viseras. MDPI Telecom. - *Lesson learnt from AI applied to Manufacturing*. Chapter contribution to book “AI for Digitazing industry: technology“ from River Publishing. - *A Comparative Study of Least Squares Refinement Methods for IEEE 802.11p Channel Estimation*. Daniel Wessel, Sheikh Usman Ali, Fatma Merve Karali, Andreas Weber, Florian Geiser, and Alberto Viseras. Submitted to IEEE Access. (eingereicht)

Tabelle 2

Studentische Arbeiten
- *Synchronisation and Signal Detection in Wireless Communications: A Deep Learning Approach*. Sheikh Usman Ali. Masterarbeit. Chair of Coding and Cryptography Technische Universität München. - *Traffic Classification on OFDM 802.11p Waveforms using a Deep Convolutional Neural Network*. Jan Irsperger. Research Internship. Lehrstuhl für Nachrichtentechnik Technische Universität München - *Comparison of Deep Learning Models for Channel Estimation Task*. Fatma Merve Karali. Interdisciplinary Internship. Technische Universität München

Tabelle 3

Fachvorträge
• F. Geiser: Reinforcement Learning in Mobile Communication Networks: Using OpenAI Gym and GNU Radio to Improve 5G, South Tyrol Free Software Conference (SFScon), 13.11.2021, Bolzano, Italien

4 Industrieller Nutzen und Verwertbarkeit

Die Motius GmbH konnte durch die Beteiligung an FunKI ihr Know-how im Bereich Kommunikationstechnik und Künstliche Intelligenz miteinander kombinieren und weiter vertiefen. Durch diese frühe Beteiligung an innovativen Forschungsfragen erweiterte Motius ihr Portfolio an verwendeten Technologien. Das erlangte Wissen kam zusätzlich einer Vielzahl der laufenden Projekte und Partner zugute. Das Start-Up erweiterte mit der Beteiligung an diesem Forschungsprojekt seine Partnerschaften mit Universitäten und führenden Industrieunternehmen in Deutschland. Durch die Präsentation der Ergebnisse auf relevanten Konferenzen erhöhte sich des Weiteren die Sichtbarkeit des Unternehmens, was langfristig zu neuen Projekten und Kooperationen führte. Somit konnte Motius sich weiterhin als zuverlässiger und innovativer Forschungs- und Entwicklungspartner am Markt behaupten.

Zusätzlich zur Erweiterung ihres technischen Wissens und Netzwerks ermöglichte das FunKI-Projekt Motius auch den Zugang zu fortschrittlichen Forschungsressourcen und spezialisierten Einrichtungen. Diese Ressourcen halfen dem Unternehmen, die Effizienz und Qualität ihrer Projekte weiter zu steigern. Das Projekt förderte die interdisziplinäre Zusammenarbeit zwischen verschiedenen Abteilungen innerhalb von Motius und stärkte das interne Innovationspotenzial.

Die Teilnahme an FunKI bot Motius auch die Gelegenheit, neue Märkte zu erkunden und ihre Präsenz in der Industrie 4.0 zu festigen. Mit der Entwicklung von maßgeschneiderten Lösungen für komplexe Kommunikationsprobleme konnte das Unternehmen seine Kundenbasis erweitern und neue Geschäftsmöglichkeiten erschließen. Die gewonnenen Erkenntnisse und Technologien wurden in die Produktentwicklung integriert, was zu wettbewerbsfähigen und zukunftssicheren Angeboten führte.

Darüber hinaus förderte die Zusammenarbeit mit führenden Forschungseinrichtungen und Industriepartnern den Austausch von Best Practices und neuesten Erkenntnissen, was die Innovationsfähigkeit von Motius weiter stärkte. Die durch das Projekt gewonnenen Daten und Ergebnisse wurden in wissenschaftlichen Publikationen veröffentlicht, was zur akademischen Reputation von Motius beitrug und das Unternehmen als wichtigen Akteur in der Forschungsgemeinschaft positionierte.

Insgesamt hat die Teilnahme am FunKI-Projekt Motius nicht nur dabei geholfen, ihr technisches Portfolio zu erweitern und neue Partnerschaften zu knüpfen, sondern auch ihre Position als Innovator in der Kommunikations- und KI-Technologie zu festigen. Die positiven Auswirkungen des Projekts werden noch lange nach Abschluss des Projekts spürbar sein, da Motius weiterhin die gewonnenen Erkenntnisse und Netzwerke nutzen kann, um zukünftige Herausforderungen zu meistern und neue Möglichkeiten zu erschließen.

Motius Kurzbericht

5G Lab für Künstliche Intelligenz

Im Verbundprojekt

FunKI

Funkkommunikation mit Künstlicher Intelligenz

Laufzeit des Vorhabens:	**15.05.2020 - 14.11.2023**
Förderkennzeichen:	**16KIS1183**

Motius GmbH
Walter-Gropius-Str 17
D-80807 München

Ansprechpartner:
Alberto Viseras alberto.viseras@motius.de +49 176 9775 8305

1 Wissenschaftlich-technische Ergebnisse und andere wesentliche Ereignisse

1.1 AP 1: Projektkoordination und -Kommunikation, Anwendungsfälle und Szenarien

Motius unterstützte bei der Aktualisierung der Website-Elemente, welche Partnerbeschreibungen und eine Liste projektbezogener Veröffentlichungen umfassten. Motius nahm regelmäßig an Konsortialsitzungen für die verschiedenen Arbeitspakete teil und führte einen Online-Workshop zur Einführung der Projektpartner in die Grundlagen von GNU-Radio durch. Zusammen mit Creonic wurde ein Präsenztreffen organisiert, um die Roadmap und die nächsten Schritte für den Aufbau eines Demonstrators im AP 5 zu diskutieren. Zudem präsentierte Florian Geiser vom Motius-Team die Arbeit auf der SFSCon-Konferenz. In den Anwendungsfällen und Szenarien definierte Motius industrierelevante Use Case Gruppen und Beispiele sowie die entsprechenden Service-Level-Anforderungen und KPIs in Zusammenarbeit mit den verantwortlichen Partnern.

1.2 AP 2: Sende- und Empfängerstrukturen

Motius hat spezialisierte Verarbeitungsblöcke für die iterative Signaldetektion (MIMO, Entzerrung) und Decodierung zu einem eingelernten Block (DNN, RNN, CNN) mit reduzierter Latenz zusammengelegt. Verschiedene ML-Ansätze wurden analysiert, um die drahtlose Kommunikation in Fahrzeugumgebungen zu verbessern. Der Einsatz von Deep Learning zur Synchronisierung und Signalerfassung für IEEE 802.11p wurde vorgeschlagen und die Ergebnisse in einer Masterarbeit veröffentlicht. Für die MIMO-Kanalschätzung und -entzerrung wurden nach Literaturrecherche neuronale Netzarchitekturen ausgewählt, implementiert und mit Nokia-Kanalmessungen sowie klassischen Modellen bewertet. MIMO-OFDM-Systeme wurden durch modifizierte GNU-Radio-Pipelines angepasst, um neuronale Netze zu integrieren. Zudem wurden geeignete ML-Verfahren für die Signalverarbeitungskette von Mehrträgermodulationsverfahren untersucht und mehrere Netzarchitekturen hinsichtlich Leistung und Ressourcenbedarf verglichen.

1.3 AP 3: Kanaladaption

Motius hat einen Deep Reinforcement Learning (DRL)-Ansatz zur Link-Adaption implementiert und evaluiert. Zwei state-of-the-art actor-critic DRL-Algorithmen wurden entwickelt, um den Durchsatz zu optimieren, und auf simulierten sowie voraufgezeichneten realen Kanälen getestet. Für die Kanalparameterschätzung wurden vielversprechende Deep-Learning-Modelle, insbesondere Entrausch- und Superresolution-Architekturen, verwendet. Die Trainings- und Evaluierungspipelines wurden entwickelt, das Training der neuronalen Netze sowie die Optimierung der Hyperparameter erfolgreich abgeschlossen. Methoden zur Verkehrsklassifizierung auf OFDM 802.11p-Wellenformen mit einem Deep Convolutional Neural Network erreichten eine Genauigkeit von 90 % und zeigten sich robust über einen breiten Bereich von SNRs, einschließlich Fading- und entzerrter Fading-Kanalfälle.

1.4 AP 4: Effiziente Implementierung von Transceivern

Die Motius GmbH ist nicht direkt an den Arbeiten in AP4 beteiligt.

1.5 AP 5: SDR Demonstrator

Motius hat in Zusammenarbeit mit ***Creonic*** und den Projektpartnern geeignete Demonstrationsszenarien festgelegt, insbesondere für die Demonstration der Kanalschätzung mittels KI unter dem Namen “Refined Least Square Channel Estimation”. Die Schnittstellen wurden gemeinsam mit Creonic definiert, und eine Pipeline zur Testung und Bewertung des Algorithmus wurde entwickelt. Diese Pipeline wurde an Creonic übergeben, um das neuronale Netz auf dem FPGA zu implementieren. Unter den Netzwerkkandidaten wurde sich auf ein finales CNN festgelegt, welches im Anschluss von ***Creonic*** synthetisiert wurde. Die Größe des Netzwerkes, insbesondere in den Input-Layern, überschritt hierbei die Größe des eingesetzten FPGA, sodass hierbei leider kein Messedemonstrator präsentiert werden konnte.

2 Veröffentlichungen

Tabelle 1:

Wissenschaftliche Publikationen
- *DRLLA: Deep Reinforcement Learning for Link Adaption*. Florian Geiser, Daniel Wessel, Matthias Hummert, Andreas Weber, Dirk Wübben, Armin Dekorsy, and Alberto Viseras. MDPI Telecom. - *Lesson learnt from AI applied to Manufacturing*. Chapter contribution to book "AI for Digitazing industry: technology" from River Publishing. - *A Comparative Study of Least Squares Refinement Methods for IEEE 802.11p Channel Estimation*. Daniel Wessel, Sheikh Usman Ali, Fatma Merve Karali, Andreas Weber, Florian Geiser, and Alberto Viseras. Submitted to IEEE Access. (eingereicht)

Tabelle 2

Studentische Arbeiten
- *Synchronisation and Signal Detection in Wireless Communications: A Deep Learning Approach*. Sheikh Usman Ali. Masterarbeit. Chair of Coding and Cryptography Technische Universität München. - *Traffic Classification on OFDM 802.11p Waveforms using a Deep Convolutional Neural Network*. Jan Irsperger. Research Internship. Lehrstuhl für Nachrichtentechnik Technische Universität München - *Comparison of Deep Learning Models for Channel Estimation Task*. Fatma Merve Karali. Interdisciplinary Internship. Technische Universität München

Tabelle 3

Fachvorträge
• F. Geiser: Reinforcement Learning in Mobile Communication Networks: Using OpenAI Gym and GNU Radio to Improve 5G, South Tyrol Free Software Conference (SFScon), 13.11.2021, Bolzano, Italien

3 Industrieller Nutzen und Verwertbarkeit

Die Motius GmbH konnte durch die Beteiligung an FunKI ihr Know-how im Bereich Kommunikationstechnik und Künstliche Intelligenz miteinander kombinieren und weiter vertiefen. Durch diese frühe Beteiligung an innovativen Forschungsfragen erweiterte Motius ihr Portfolio an verwendeten Technologien. Das erlangte Wissen kam zusätzlich einer Vielzahl der laufenden Projekte und Partner zugute. Das Start-Up erweiterte mit der Beteiligung an diesem Forschungsprojekt seine Partnerschaften mit Universitäten und führenden Industrieunternehmen in Deutschland. Durch die Präsentation der Ergebnisse auf relevanten Konferenzen erhöhte sich des Weiteren die Sichtbarkeit des Unternehmens, was langfristig zu neuen Projekten und Kooperationen führte. Somit konnte Motius sich weiterhin als zuverlässiger und innovativer Forschungs- und Entwicklungspartner am Markt behaupten.