

TECHNISCHE UNIVERSITÄT MÜNCHEN  
Lehrstuhl für Regelungstechnik

# Optimierung und Applikation von Betriebsstrategien in Hybridfahrzeugen

Dipl.-Ing. Andy Sittig

Vollständiger Abdruck der von der Fakultät für Maschinenwesen der  
Technischen Universität München zur Erlangung des akademischen Grades eines

Doktor-Ingenieurs  
genehmigten Dissertation.

Vorsitzender: Univ.-Prof. Dr.-Ing. Karsten Stahl  
Prüfer der Dissertation: 1. Univ.-Prof. Dr.-Ing. habil. Boris Lohmann  
2. Univ.-Prof. Dr.-Ing. Georg Wachtmeister

Die Dissertation wurde am 13.11.2013 bei der Technischen Universität München  
eingereicht und durch die Fakultät für Maschinenwesen am 26.05.2014 angenommen.



# Vorwort

Die vorliegende Arbeit entstand während meiner Tätigkeit als Doktorand bei der BMW AG in der Abteilung Konzepte und Betriebsstrategie Hybrid in München.

Mein herzlicher Dank gilt meinem Doktorvater Prof. Dr. Boris Lohmann für die wissenschaftliche Betreuung und die unkomplizierte Zusammenarbeit. Ebenso danke ich Herrn Prof. Dr.-Ing. Georg Wachtmeister für das entgegengebrachte Interesse an meiner Arbeit und die Erstellung des Zweitgutachtens. Herrn Prof. Dr.-Ing. Karsten Stahl danke ich für die Übernahme des Vorsitzes beim Rigorosum.

Herrn Dr. Friedrich Rabenstein danke ich für die Möglichkeit eine wissenschaftliche Arbeit im Rahmen eines Hybridserienprojekts anfertigen zu dürfen. Ganz besonders danken möchte ich Herrn Bernhard Ludwig sowohl für die fortwährende fachliche Unterstützung als auch für den persönlichen Zuspruch. Sein außerordentliches Interesse und seine Ratschläge haben entscheidend zum Gelingen der Arbeit beigetragen. Ebenso danke ich Herrn Georg Mumelter für den wertvollen fachlichen Austausch bei der Entstehung dieser Arbeit.

Ein großer Dank geht an die von mir betreuten Praktikanten Herrn Michael Steinberger, Herrn Andreas Stroka, Herrn Marco Naubert, Herrn Andre Dilong und Herrn Christoph Bals für deren unermüdlichen Einsatz und Unterstützung. Außerdem möchte ich mich bei Herrn Dennis Schatz, Herrn Alexander Schels und Herrn Christoph Hildebrandt bedanken, deren Abschlussarbeiten wertvolle Ergebnisse lieferten.

Allen Teamkollegen der vergangenen Jahre danke ich für die zahlreichen fachlichen Diskussionen und nichtfachlichen Gespräche - besonders erwähnen möchte ich Herrn Hans-Peter Knetsch und Herrn Albert Bauer sowie Herrn Dr.-Ing. Thomas Salcher.

Nicht zuletzt danke ich meinen Eltern und meiner Familie für ihre Unterstützung. Mein größter Dank gilt Tanja für ihre Geduld, ihr Verständnis und ihren Beistand auf dem Weg zur Erlangung der Doktorwürde.

München, im November 2013

Andy Sittig



# Kurzfassung

Die Betriebsstrategie eines Hybridfahrzeugs ist durch ihre hohe Komplexität und den vielfältigen Querwirkungen auch in der späten Entwicklungsphase nur schwer im Fahrzeug zu parametrieren. In der vorliegenden Arbeit wird eine Methode zur Optimierung der Betriebsstrategie in Hybridelektrofahrzeugen entwickelt und im realen Serienentwicklungsprozess angewendet. Zur Lösung von multikriteriellen Optimierungsproblemen werden ein genetischer Algorithmus und ein Simulationsmodell, welches die realen Steuergerätefunktionen und- parameter beinhaltet, kombiniert.

Die vorgestellte Methode wird anhand von ausgewählten Fahrzyklen bewertet. Es werden konkrete Problemstellungen untersucht, bei denen der Kraftstoffverbrauch als wichtigste Zielgröße jeweils im Konflikt mit einem weiteren Zielkriterium steht. Mithilfe eines Pareto-basierten genetischen Algorithmus lassen sich mögliche Kompromisslösungen darstellen und Sensitivitäten zwischen den Entscheidungsvariablen und Zielgrößen aufzeigen. Die approximierten Pareto-Fronten werden mithilfe eines Hybridantriebsprüfstands am realen Antriebsstrang durch Auswertung einzelner Lösungspunkte validiert.



# Summary

Due to high complexity and its various correlations the parametrization of the operating strategy of hybrid electric vehicles is a difficult task even in the later stages of the development process. This work proposes an approach to optimize the operating strategy of hybrid electric vehicles. The method is applied and tested during a series development process. To solve multi-objective optimization problems a genetic algorithm and a simulation model which includes the real control unit functions and parameters are combined.

The introduced method is evaluated on the basis of selected driving cycles. Different practical problems with conflicting goals such as low fuel consumption and high electric drive availability are analyzed. The usage of a pareto-based genetic algorithm provides a set of compromise solutions. Furthermore correlations between parameters and target values are revealed. The optimization results are validated with the help of a hybrid power train test bench.





# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
1.1	Entwicklungen im Automobilbereich . . . . .	1
1.2	Entwicklungsprozess und -plattformen . . . . .	4
1.2.1	Entwicklungsprozess . . . . .	4
1.2.2	Entwicklungsplattformen . . . . .	5
1.3	Wissenschaftliche Zielsetzungen der Arbeit . . . . .	9
1.4	Aufbau der Arbeit . . . . .	9
<b>2</b>	<b>Grundlagen und Stand der Technik</b>	<b>11</b>
2.1	Einordnung hybrider Antriebe . . . . .	11
2.2	Hybridantriebsfunktionen . . . . .	14
2.3	Betriebsstrategien in Hybridfahrzeugen . . . . .	16
2.4	Multikriterielle Optimierung . . . . .	18
2.4.1	Einordnung und Definitionen . . . . .	18
2.4.2	Lösungsmethoden . . . . .	21
2.4.3	Genetische Algorithmen . . . . .	29
2.4.4	Unterschiede und Eignung der Verfahren . . . . .	33
<b>3</b>	<b>Betrachteter Antriebsstrang</b>	<b>39</b>
3.1	Gesamtfahrzeug . . . . .	39
3.1.1	Verbrennungsmotor . . . . .	40
3.1.2	E-Maschine und Leistungselektronik . . . . .	43
3.1.3	Getriebe . . . . .	45
3.1.4	Hochvoltspeicher . . . . .	46
3.2	Antriebsprüfstand . . . . .	49
3.3	Kernfunktionen Betriebsstrategie . . . . .	54
3.3.1	Ladezustandsregelung . . . . .	54
3.3.2	Elektrische Fahrentscheidung . . . . .	58
3.4	Validierung des Prüfstands . . . . .	61

<b>4 Methode zur Optimierung und Applikation der Betriebsstrategie</b>	<b>65</b>
4.1 Simulationsumgebung . . . . .	66
4.1.1 Simulationskonzept . . . . .	68
4.1.2 Simulationsmodelle . . . . .	71
4.2 Kombination von Simulation und Antriebsprüfstand im Applikationsprozess	78
4.3 Multikriterieller Optimierungsalgorithmus . . . . .	80
4.3.1 Basisalgorithmus NSGA-II . . . . .	80
4.3.2 Anpassungen und Erweiterungen des Algorithmus . . . . .	87
<b>5 Einsatz und Bewertung der Methode im Praxisbetrieb</b>	<b>95</b>
5.1 Vorbetrachtungen und Problemformulierung . . . . .	95
5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen . .	100
5.2.1 Betriebsstrategieoptimierung im NEFZ . . . . .	100
5.2.2 Betriebsstrategieoptimierung im FTP-72 . . . . .	109
5.3 Betriebsstrategieoptimierung im Kundenzyklus . . . . .	118
<b>6 Zusammenfassung und Ausblick</b>	<b>123</b>
<b>Abkürzungs- und Symbolverzeichnis</b>	<b>127</b>
<b>Abbildungsverzeichnis</b>	<b>133</b>
<b>Tabellenverzeichnis</b>	<b>137</b>
<b>Literaturverzeichnis</b>	<b>139</b>

# Kapitel 1

## Einleitung

### 1.1 Entwicklungen im Automobilbereich

Das Global Economic Symposium (GES), ein weltweiter Zusammenschluss führender Experten aus Wirtschaft, Politik und Wissenschaft, zählt zu den dringlichsten Herausforderungen der Menschheit die Beherrschung des Klimawandels und der Energiekrise [167]. Dabei gilt es den Ausstoß von Treibhausgasen zu reduzieren und Anpassungsmaßnahmen zur Bewältigung globaler Umweltfolgen einzuleiten. Die unsichere Energiezukunft und die anhaltende Diskussion zur Klimaveränderung rücken auch alternative Antriebskonzepte für die individuelle Mobilität immer stärker in den Fokus der Öffentlichkeit. Der Anteil des Straßenverkehrs an den weltweiten anthropogenen Kohlendioxid-Emissionen ( $CO_2$ ) durch Verbrennung fossiler Energieträger betrug im Jahr 2010 ca. 16 % [97]. In den OECD-Staaten<sup>1</sup> sind es ca. 24 % (Abbildung 1.1). Mehr als die Hälfte des  $CO_2$ -Ausstoßes im Straßenverkehr entfällt dabei auf den PKW<sup>2</sup>-Sektor - in Deutschland sind es fast 60 %. Nicht zuletzt vor dem Hintergrund der prognostizierten stark wachsenden Verkehrsleistungen stellen nachhaltige Mobilitätslösungen einen wesentlichen Beitrag zur gesellschaftlichen Verantwortung global agierender Automobilhersteller dar.

In den wichtigsten Automobilmärkten existieren bereits Gesetzgebungen bzw. fakultative Zusagen mit dem Ziel, die  $CO_2$ -Emissionen des individuellen Personenverkehrs zu reduzieren. Die Vereinigung europäischer Automobilhersteller (ACEA<sup>3</sup>) etwa hat sich in einer freiwilligen Selbstverpflichtung 1998 darauf geeinigt die durchschnittlichen  $CO_2$ -Emissionen neuzugelassener Fahrzeuge<sup>4</sup> bis zum Ende des Jahres 2008 auf  $140 \text{ g}^{CO_2}/\text{km}$  zu reduzieren [56]. Für das Jahr 2012 wurde ein Gemeinschaftsziel von

---

<sup>1</sup>Organisation for Economic Co-operation and Development

<sup>2</sup>Personenkraftwagen

<sup>3</sup>Association des Constructeurs Européens d'Automobiles

<sup>4</sup>durchschnittlicher Flottenverbrauch der Neuzulassungen in einem Jahr




Abbildung 1.1: Verteilung der  $CO_2$ -Emissionen in den OECD-Staaten im Jahr 2010 [97]

120 g $CO_2$ /km<sup>5</sup> ausgegeben [57]. Zwar konnte die Effizienz von Personenkraftwagen seit 1995 um 15 % gesteigert werden, dennoch hielt die EU ein Eingreifen in die Selbstverpflichtung der Autohersteller für unabdingbar. Mit der Verordnung (EG) Nr. 443/2009 schuf die Europäische Kommission einen verbindlichen Rechtsrahmen und beschloss die stufenweise Umsetzung des 120 g $CO_2$ /km-Ziels bis 2015. Ein Wert von 130 g $CO_2$ /km ist durch verbrennungsmotorische<sup>6</sup>- und fahrzeugtechnische<sup>7</sup> Maßnahmen sowie innovative Technologien zu erreichen, während weitere 10 g $CO_2$ /km durch ergänzende Maßnahmen wie z.B. Biokraftstoffe eingespart werden können. Außerdem wurde eine Emissionsüberschreitungsabgabe für Herstellerflotten definiert. Die Zielwerte sind abhängig vom Fahrzeuggewicht und damit von Hersteller zu Hersteller verschieden. Zudem wird als Ziel für die Neuwagenflotte ab 2020 ein Wert von 95 g $CO_2$ /km festgelegt [41]. Hybridelektrofahrzeuge (HEV<sup>8</sup>) können zur Erreichung der  $CO_2$ -Ziele einen erheblichen Beitrag leisten, wenn gleich hierfür große Stückzahlen notwendig sind. Neben Europa existiert das in den USA von der CARB<sup>9</sup> eingeführte LEV-Programm<sup>10</sup>, welches anfänglich von

<sup>5</sup>Das entspricht einem durchschnittlichen Verbrauch von ca. 5.1l Benzin oder ca. 4.5l Diesel.

<sup>6</sup>Brennverfahrensoptimierung, Reibungsreduzierung, Hochaufladung

<sup>7</sup>Reduzierung der Fahrwiderstände (Luft-, Rollwiderstand, Gewicht), Nutzung alternativer Energieträger

<sup>8</sup>Hybrid Electric Vehicle

<sup>9</sup>California Air Resources Board

<sup>10</sup>Low Emission Vehicle = Niedrig-Emissions-Fahrzeug

Kalifornien und später von weiteren Bundesstaaten übernommen wurde. Es forciert durch strenge Emissionsstandards die Einführung neuer Technologien bzw. Elektrifizierung des Antriebsstrangs bei den Automobilherstellern [30, 90].

Neben einem erhöhten Umweltbewusstsein spielen vor allem auch ökonomische Aspekte beim Fahrzeugkauf eine Rolle [122]. Stetig steigende Kraftstoffpreise und deren Abhängigkeit von politischen Faktoren erfordern verbrauchsreduzierende Maßnahmen aus Kundensicht. Des Weiteren bedingt auch die Endlichkeit der fossilen Kraftstoffe die Entwicklung alternativer Antriebskonzepte. Weitere Kauffaktoren sind  $CO_2$ -basierte Besteuerungssysteme für die Zulassung und den Betrieb von PKW oder Einfahrtbeschränkungen in Städte. Weltweit existieren zudem vermehrt Kaufanreize für Fahrzeuge mit geringem  $CO_2$ -Ausstoß. Diese reichen von der Befreiung bzw. Reduzierung der Zulassungssteuer und/oder der jährlichen Kraftfahrzeugsteuer bis hin zu Kaufpreisförderungen in Form direkter Zuschüsse. Hatten Hybridelektrofahrzeuge im Jahr 2012 noch einen Anteil von 0.7 % an den Fahrzeugneuzulassungen in Deutschland [96], wird die Zahl an Fahrzeugen mit elektrifizierten Antrieben in den nächsten Jahren stetig zunehmen, wengleich die prognostizierten Marktanteile weit auseinander gehen [153, 156, 122, 90].

Die konventionellen Antriebe mit Verbrennungsmotor unterliegen durch die zunehmende Verschärfung der Emissionsgrenzwerte und der  $CO_2$ -Ziele bei gleichzeitiger Berücksichtigung der Kundenanforderungen einen stetigen Wandel. Neue Motorenkonzepte mit technisch aufwändigen Lösungen und die zunehmende funktionale Vernetzung führen zu einer stetig wachsenden Anzahl an Applikationsparametern [16]. Gerade Fahrzeuge der oberen Fahrzeugsegmente werden die  $CO_2$ -Ziele durch fahrwiderstandsreduzierende Maßnahmen und Optimierung des Verbrennungsmotors alleine kaum erreichen können. Die Hybridisierung bzw. Elektrifizierung des Antriebsstrangs ist ein nachhaltiger Ansatz zur Erfüllung der Gesetzesanforderungen sowie der Kundenerwartungen hinsichtlich Kraftstoffverbrauch und Dynamik. Zusätzliche Komponenten und Steuergeräte im hybriden Antriebsstrang führen jedoch zu einer noch stärkeren Vernetzung der Steuergerätefunktionen und einen zusätzlichen Anstieg der Parameter [20, 182, 161]. Die Beherrschung der Komplexität im Serienentwicklungsprozess von Hybridfahrzeugen erfordert daher die Entwicklung und den Einsatz neuer Werkzeuge und Methoden [102, 1, 14, 15, 117, 113, 71]. Durch eine geeignete Methoden-anwendung kann die Effizienz (Einsparung von Zeit und Kosten, Ableitung von Derivaten) und Qualität im Applikationsprozess gesteigert werden [154].

## 1.2 Entwicklungsprozess und -plattformen

### 1.2.1 Entwicklungsprozess

Der Prozess der Funktions- und Softwareentwicklung im Automotive-Bereich orientiert sich am sog. V-Modell (Abbildung 1.2). Das V-Modell<sup>11</sup> definiert eine systematische

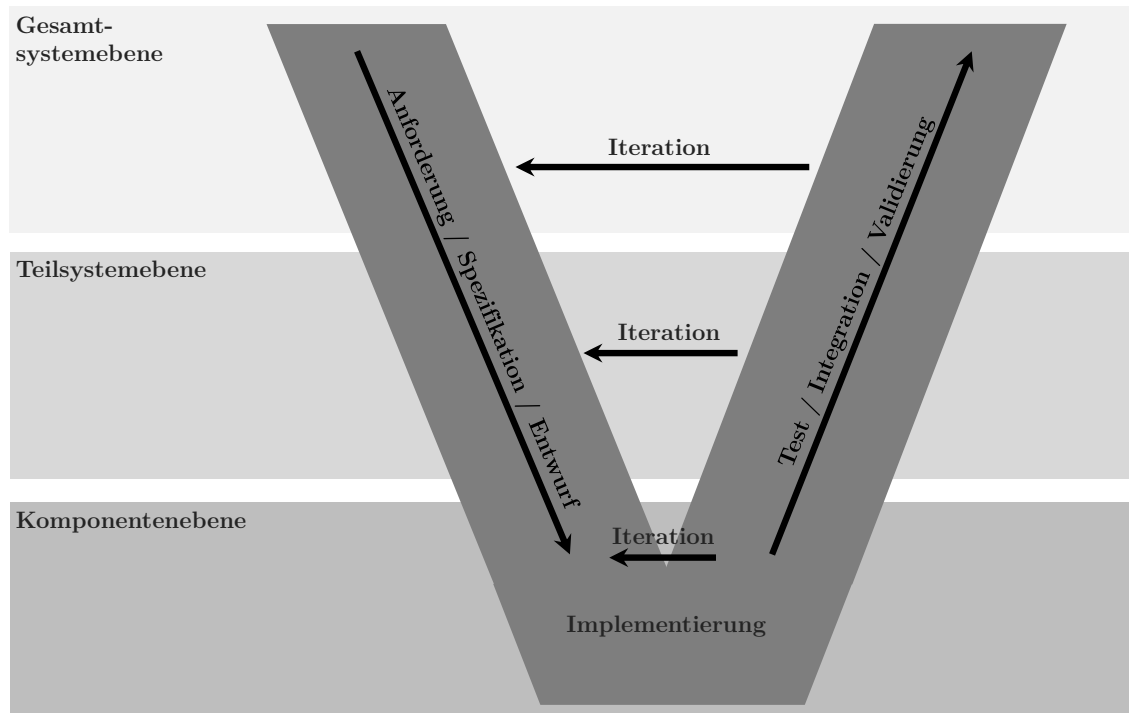


Abbildung 1.2: Vereinfachtes V-Modell zum automobilen Softwareentwicklungsprozess

und phasenorientierte Vorgehensweise in Entwicklungsprojekten von qualitäts- sowie sicherheitskritischen Produkten und wird vielfach bei der Softwareerstellung für Fahrzeugsteuergeräte übernommen [173]. Es ermöglicht eine Detaillierung der einzelnen Prozessschritte und erlaubt die Koordination der Arbeitspakete und Verantwortlichkeiten an die unterschiedlichen Fachabteilungen. Das Modell beschreibt im linken Teil die Phasen der Systemerstellung von der Anforderung bis hin zur Implementierung bzw. Umsetzung abhängig von den einzelnen Systemebenen (Gesamtssystem, Teilsystem, Komponente). Der rechte Teil definiert Tests auf den einzelnen Ebenen zum Abprüfen der jeweiligen Spezifikation des linken Teils bis hin zur Systemabnahme.

<sup>11</sup>Seit 2005 ist das V-Modell unter der Bezeichnung V-Modell XT als Entwicklungsstandard für IT-Systeme des zivilen und militärischen Bereichs des Bundes empfohlen bzw. verbindlich vorgeschrieben [147].

Das V-Modell wird im Laufe der Gesamtfahrzeugentwicklung bis zur Serienreife<sup>12</sup> über mehrere Jahre hinweg wiederholt durchlaufen, wodurch neue Anforderungen in der Entwicklung berücksichtigt werden können. Dabei orientiert man sich in der Automobilindustrie typischerweise an einen festen Projektendtermin (SOP-Termin<sup>13</sup>). Die systematische Verifikation und Validierung ermöglicht einen iterativen Entwicklungsprozess, welcher es erlaubt, Fehler z.B. in der Anforderung oder im Entwurf aufzudecken und zu korrigieren. Durch den ursprünglich sequentiellen Prozess der Hard- und Softwareentwicklung können Qualitätsprobleme teilweise erst sehr spät, z.B. während des Gesamtfahrzeugtests, festgestellt werden. Mithilfe virtueller Entwicklungsmethodik kann durch das parallele Entwickeln von Hard- und Software Entwicklungszeit eingespart und Fehler deutlich früher erkannt werden.

Neben der eigentlichen Funktionsentwicklung ist die Funktionsparametrierung<sup>14</sup> der entscheidende Entwicklungsschritt, der sowohl die Ausprägung als auch die Qualität des Fahrzeugs maßgeblich beeinflusst. Durch virtuelle Absicherung und Applikation kann der Zeit- und Kostenaufwand für Tests im rechten Teil des V-Modells erheblich reduziert werden.

### 1.2.2 Entwicklungsplattformen

Test und Applikation der entwickelten Antriebsfunktionen können auf unterschiedlichen Entwicklungsplattformen durchgeführt werden (Abbildung 1.3). Diese bilden jeweils einen Teil des Fahrzeugantriebs, angefangen bei einzelnen Modulen (Steuergeräte) und Komponenten (Motorprüfstand) über Teilsysteme (Antriebsstrangprüfstand) bis hin zum Gesamtsystem (Fahrzeug auf Rollenprüfstand oder auf Versuchsstrecke), unter Anwendung umgebungsspezifischer Methoden, ab [113]. Die Simulation ist ein wichtiger Bestandteil der einzelnen Plattformen und kann ferner auch als eine eigenständige Entwicklungsumgebung betrachtet werden.

Gerade für die frühe Entwicklungsphase existiert eine Vielzahl von Simulationstools (Umgebungen), mit denen entweder Teilsysteme oder der gesamte Antriebsstrang simuliert werden können [125, 117, 124, 75, 176, 35, 119, 126, 4, 66, 5, 143]. Den verwendeten Modellen liegt dabei entweder eine kausale, signalorientierte Modellierung, z.B. mit Matlab/Simulink [185], oder eine akausale, physikalische Modellierung, z.B. mit Dymola/Modelica [186, 74], zu Grunde. Sie eignen sich für die optimale Auslegung von Fahrzeugkomponenten oder der Betriebsstrategie in der Konzeptphase. Nachteilig ist die

---

<sup>12</sup>einen Entwicklungsstand aufweisend, der die Serienanfertigung ermöglicht

<sup>13</sup>Start of Production; Zeitpunkt des Produktionsanlaufes

<sup>14</sup>Diesen Vorgang bezeichnet man als Applikation.

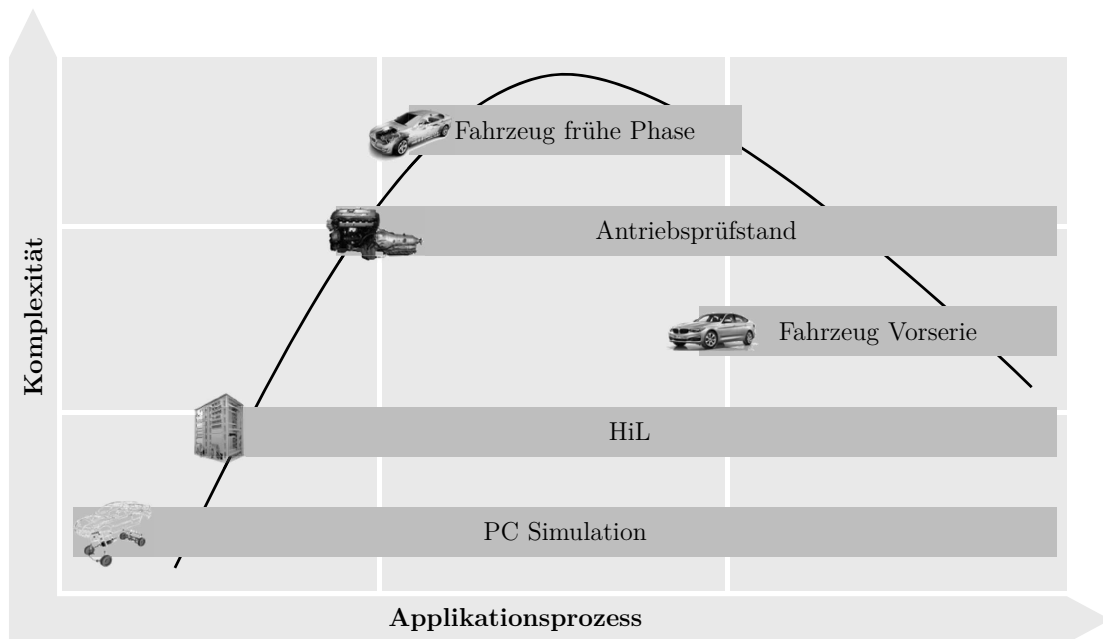


Abbildung 1.3: Applikationsplattformen Hybrid-Betriebsstrategie

meist hohe Modellkomplexität und die damit verbundene Bereitstellung der notwendigen Rechenleistung. Die Berücksichtigung der originalen Steuererätefunktionen, was für den Applikationsprozess unerlässlich ist, ist ebenfalls schwierig. Dabei wird üblicherweise ein Teilmodell oder auch das Gesamtmodell der späteren Software in einer Simulationsumgebung verwendet (MiL)<sup>15</sup>. Einige kommerzielle Anwendungen bieten zusätzliche Schnittstellen für die Integration von realen Steuererätefunktionen in die Simulation [120, 163]. Sie sind allerdings schwierig in einen bestehenden Serienentwicklungsprozess zu integrieren.

Mithilfe von Hardware-in-the-Loop (HiL)-Prüfständen können Steuereräte in einer virtuellen Umgebung getestet werden. Dabei werden ein oder mehrere Steuereräte entsprechend ihrer Schnittstellen mit Signalen von Sensoren, Aktoren und Buskommunikationssystemen analog zum späteren Fahrzeug verbunden. Die für diesen Zweck auf zusätzlichen Simulationsrechnern verwendeten Simulationsmodelle müssen die Schnittstellen in Echtzeit bedienen [168, 208, 164, 133, 55].

Die beschriebenen HiL-Prüfstände sind vorteilhaft zum Testen der prinzipiellen Funktionsfähigkeit, zur Überprüfung der Kommunikation sowie für die Freigabe und Absicherung von Datenständen einsetzbar. Ferner ist z.B. ein gefahrenloses Testen von Fehlfunktionen und möglichen Grenzfällen ohne reale Fahrversuche möglich. Für

<sup>15</sup>MiL - Modell-in-the-Loop



den Einsatz zur Applikation von Hybridfunktionen wird ein entsprechend detailliertes Modell des Antriebsstrangs gefordert, was im Allgemeinen im Widerspruch zur Echtzeitanforderung steht. Zusätzlich steigen Zeit- und Kostenaufwand überproportional mit der geforderten Güte des Simulationsmodells an.

Erweiterte HiL-Anwendungen, welche neben dem Steuergerät zusätzlich auch mechanische Antriebsstrangkomponenten, z.B. den Verbrennungsmotor (EiL)<sup>16</sup>, als reale Komponenten verbaut haben, erlauben Aussagen zum Kraftstoffverbrauch sowie zu Emissionen [121, 166, 14, 95, 205]. Der restliche Antriebsstrang muss allerdings wie bei einem konventionellen HiL-Prüfstand in Echtzeit simuliert und über definierte Schnittstellen vernetzt werden. Solche Konfigurationen erlauben z.B. das Abfahren gesetzlicher Fahrzyklen und eine Analyse möglicher Kraftstoffverbrauchspotenziale. Nachteilig ist die schwierige Einbindung der realen Funktionen des Hybridsteuergeräts und damit das Ableiten konkreter Parametrierungen für die Hybridbetriebsstrategie.

Bei einem Antriebsstrangprüfstand sind neben dem Verbrennungsmotor weitere Komponenten wie Getriebe oder Elektromaschine (E-Maschine, EM) ebenfalls in Hardware vorhanden (XiL)<sup>17</sup>. Die Simulation muss für einen Zyklusbetrieb lediglich noch einen Fahrer sowie das restliche Fahrzeug abbilden. Der Hochvoltspeicher kann ebenfalls als Hardware oder per Simulationsmodell bereit gestellt werden. Das Vorhandensein des kompletten Antriebsstrangs inklusive Steuergeräte ermöglicht neben der Parametrierung der Hybridfunktionen im Systemverbund auch die Bewertung von Kraftstoffverbrauch und Schadstoffemissionen. Durch eine hohe Reproduzierbarkeit von Versuchen sowie konditionierbare Prüfstandsbedingungen kann die Effizienz (Zeit, Kosten) erhöht werden [14, 1, 19, 165].

Ein Rollenprüfstand ermöglicht Gesamtfahrzeugtests unter reproduzierbaren Umgebungsbedingungen. Dieser simuliert dabei die Schwungmasse und den Fahrwiderstand des realen Fahrzeugs. Das Abfahren genormter Fahrzyklen auf dem Rollenprüfstand ist ferner entscheidend für die offizielle Angabe der Emissionswerte, ein wichtiger Bestandteil der weltweiten Typgenehmigungen. Nachteilig ist der hohe Zeit- und Kostenaufwand<sup>18</sup> sowie die geringe Anzahl von Tests pro Tag<sup>19</sup>.

Die Kombination von Fahrzeug und Teststrecke bzw. Straße kommt schließlich ohne die Simulation von Komponenten bzw. Fahrwiderständen aus. Die Hybridfunktionen

---

<sup>16</sup>EiL - Engine-in-the-Loop

<sup>17</sup>XiL - X-in-the-Loop

<sup>18</sup>Neben dem eigentlichen Rollenprüfstand wird zusätzlich ein Rollenfahrer benötigt.

<sup>19</sup>Gesetzliche Fahrzyklen werden typischerweise mit einer Umgebungsraumtemperatur (zwischen 20 °C und 30 °C) gefahren. Die Temperatur des Motoröls und der Kühlflüssigkeit dürfen dabei um max. 2K abweichen, was Abkühlphasen zwischen einzelnen Tests notwendig macht.

## 1 Einleitung

können im Zielsystem unter realen Bedingungen getestet und parametrisiert werden. Vollfunktionsfähige Versuchsträger mit entsprechender Entwicklungsreife stehen in den frühen Phasen allerdings kaum zur Verfügung und sind entsprechend teuer. Viele Entwicklungs- und Applikationsaufgaben können in diesem Stadium sinnvoll auf andere Plattformen verlagert werden. Für die finale Abnahme der Serienreife oder Sammlung subjektiver Erfahrungen sind Fahrzeugtests auf der Straße unerlässlich.

Der jeweilige Zeit- und Kostenaufwand der verschiedenen Plattformen ist stark abhängig vom Zeitpunkt im Entwicklungsprozess (Abbildung 1.4). Während Fahrzeug-

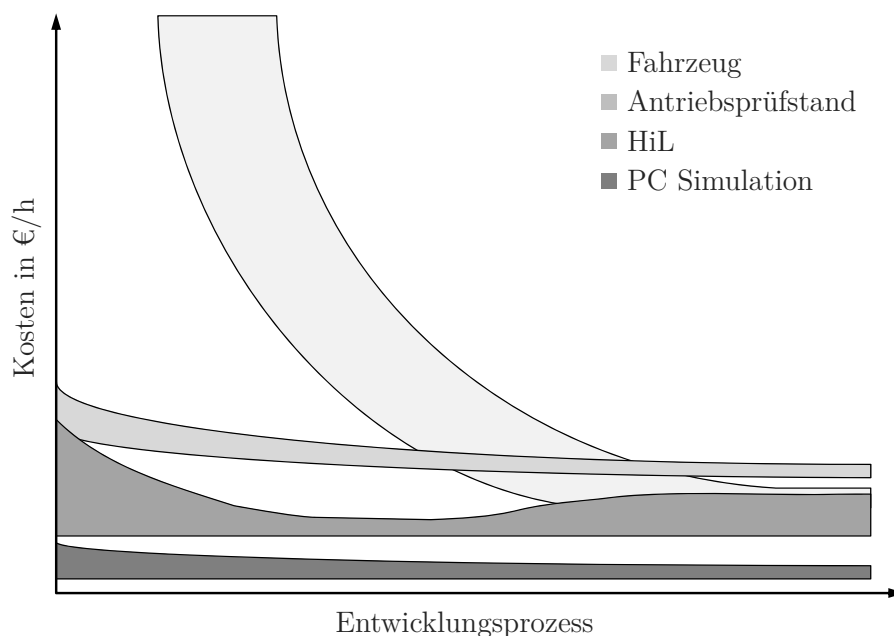


Abbildung 1.4: Kosten verschiedener Plattformen in Abhängigkeit vom Zeitpunkt im Entwicklungsprozess [154]

versuchsträger in der frühen Projektphase in der Regel teuer sind und nur in geringen Stückzahlen zur Verfügung stehen sinken die Kosten im weiteren Entwicklungsprozess mit der Nutzung seriennaher Fahrzeuge. Die Kosten für Prüfstände steigen mitunter im Verlauf der Entwicklung durch zusätzliche Anforderungen an die Abbildung des Fahrzeugs an. Die Simulation ist vergleichsweise günstig und kann über den gesamten Entwicklungsprozess für vielfältige Aufgabenstellungen gewinnbringend eingesetzt werden.

## 1.3 Wissenschaftliche Zielsetzungen der Arbeit

Die Hybridbetriebsstrategie ist durch ihre hohe Komplexität und den vielfältigen Querverwirkungen auch in der späten Entwicklungsphase nur schwer im Fahrzeug applizierbar. Erst der gezielte Einsatz alternativer Entwicklungsplattformen wie PC-Simulation und Prüfstand ermöglicht eine gezielte Auslegung der Hybridfunktionen.

Das Ziel dieser Arbeit ist der Entwurf und die Implementierung einer Entwicklungs- und Applikationsplattform für Hybridantriebsfunktionen. Das gesuchte Applikationskonzept soll über den gesamten Fahrzeugentwicklungsprozess zur Optimierung von teils konträren Zielgrößen, wie z.B. minimaler Kraftstoffverbrauch und maximale elektrische Fahrstrecke, eingesetzt werden. Im Rahmen dieser Arbeit wird deshalb erstmals ein Hybridantriebsprüfstand für die Bewertung des Kraftstoffverbrauchs des späteren Serienfahrzeugs eingesetzt. Der angestrebte Fortschritt besteht darin, dass für die Auslegung und Optimierung der Betriebsstrategieparameter keine Fahrzeugversuchsträger benötigt werden. Die in dieser Arbeit vorgestellte Kombination von PC-Simulation, Antriebsprüfstand und multikriterieller Optimierung ermöglicht die Quantifizierung des Zielkonflikts zwischen Verbrauchseffizienz, Qualität des Fahrverhaltens sowie resultierender Komponentenbelastung. Um dieses Ziel zu erreichen muss das Simulationsmodell das Systemverhalten des realen Antriebs hinreichend genau abbilden. Ein weiterer Anspruch ist die Übertragbarkeit der validierten Ergebnisse vom Antriebsprüfstand in das reale Fahrzeug. Die Integration der verwendeten Methodik in den bestehenden Entwicklungsprozess setzt u.a. auch die Definition von Schnittstellen zum Datentransfer voraus.

## 1.4 Aufbau der Arbeit

Kapitel 2 schafft einen konzeptionellen Rahmen zur Einordnung von Hybridelektrofahrzeugen und stellt die wichtigsten Funktionen zur Steuerung der Energieflüsse im Fahrzeug dar. Auf Grundlage der multikriteriellen Optimierung wird das Funktionsprinzip *genetischer Algorithmen* erläutert und eine Gegenüberstellung verschiedener Verfahren vorgenommen.

Kapitel 3 widmet sich dem in dieser Arbeit betrachteten *Antriebsstrang*. Dabei werden neben den einzelnen Komponenten auch der Aufbau und die Funktionsweise des *Hybridantriebsprüfstands* vorgestellt. Dieser wird mit einer Fahrzeugmessung in Form einer Energieanalyse validiert. Zusätzlich erfolgt eine Einführung der wesentlichen Funktionen zur Implementierung der energetischen Betriebsstrategie.

## 1 Einleitung

Kapitel 4 stellt die *entwickelte Methode* und die wesentlichen Neuerungen zur Optimierung und Applikation der Betriebsstrategiefunktionen vor. Zunächst werden das *Simulationsframework* und die verwendeten Modelle beschrieben, anschließend wird auf die Einbindung des Prüfstands in den Applikationsprozess eingegangen. Eine Darstellung des für die Optimierung verwendeten Algorithmus sowie dessen Erweiterungen schließt das Kapitel ab.

Die *Bewertung* des vorgestellten Applikationskonzepts anhand von ausgewählten Beispielen erfolgt in Kapitel 5. Nach einer Vorbetrachtung und der Formulierung von Problemstellungen wird die vorgeschlagene Methodik sowohl am Beispiel gesetzlicher Fahrzyklen als auch anhand eines Kundenprofils angewendet und bewertet.

Kapitel 6 fasst die Ergebnisse der Arbeit zusammen und gibt einen *Ausblick* für mögliche Weiterentwicklungen.

# Kapitel 2

## Grundlagen und Stand der Technik

### 2.1 Einordnung hybrider Antriebe

Der Ausdruck *hybrid* leitet sich vom lateinischen Wort *hybrida* ab und bedeutet „gemischt, von zweierlei Herkunft, aus Verschiedenartigem zusammengesetzt“ [60]. Im Automobilbereich versteht man unter einem Hybridfahrzeug ein Fahrzeug mit mindestens zwei verschiedenen Energiewandlern und zwei verschiedenen Energiespeichersystemen zum Zwecke des Fahrzeugantriebs [42]. Hybridelektrofahrzeuge kombinieren als Energiewandler einen Verbrennungsmotor mit mindestens einer E-Maschine und sind aktuell die am weitesten am Markt verbreiteten Hybridfahrzeuge. Als Energiespeichersysteme dienen dabei Kraftstofftanks und Akkumulatoren.

Abhängig von der im Fahrzeug installierten elektrischen Systemleistung und der damit verbundenen Ausprägung der Hybridfunktionen werden in der Literatur drei Kategorien von Hybridelektrofahrzeugen unterschieden [199, 134, 90, 188].

*Micro-Hybride* ermöglichen neben einer Motor-Start-Stopp-Automatik bereits eine begrenzte Bremsenergieerückgewinnung in Verzögerungsphasen (Rekuperation) [152, 36, 83, 123, 6]. Anlasser und Generator werden hierbei durch einen integrierten Startergenerator mit einer Leistung  $< 5$  kW ersetzt, während das Spannungsniveau unverändert bleibt.

*Mild-Hybride* besitzen zusätzlich zum Niedervoltbordnetz mindestens ein weiteres Energiebordnetz mit einer Spannungslage bis zu 192 V sowie eine E-Maschine mit einer Leistung von bis zu 15 kW [199]. Neben einer deutlich höheren Rekuperationsleistung ermöglicht das System eine Drehmomentenunterstützung des Verbrennungsmotors (Boosten) sowie die Funktion der Lastpunktverschiebung. Auf dem Markt befindliche Fahrzeuge sind der BMW ActiveHybrid 7 [11] und der Mercedes S400 BlueHybrid [195].

Bei *Full-Hybriden* ist ein rein elektrischer Fahrbetrieb mit abgekoppeltem Verbrennungsmotor über eine längere Distanz möglich. Die elektrische Systemleistung ( $> 20 \text{ kW}$ ) und die Spannungslage im Hochvolt-Bordnetz ( $> 190 \text{ V}$ ) sind deutlich größer als bei den Mild-Hybriden. Fahrzeugbeispiele sind der BMW ActiveHybrid X6 [22], Mercedes ML450h [61], VW Touareg Hybrid [18], Toyota Prius III [107], Audi Q5 Hybrid, Peugeot 3008 Hybrid 4 (Diesel), Lexus RX450h, CT200h, GS450h, LS600h [28, 158], Ford Fusion Hybrid und Infinity M35h. Eine Spezialform der Full-Hybride sind die *Plug-In-Hybride*. Die nochmals größere Traktionsbatterie kann bei diesen Fahrzeugen nicht nur durch Rekuperation und Lastpunktanhebung, sondern zusätzlich auch extern z.B. über ein Ladegerät aus dem Stromnetz, geladen werden [21, 211, 73, 158]. Mit voll aufgeladener Batterie sind rein elektrische Wegstrecken von bis zu 100 km möglich [90]. Bei leerem Speicher lässt sich das Fahrzeug wie ein Full-Hybridfahrzeug betreiben.

Hybridelektrofahrzeuge lassen sich zusätzlich anhand der Anordnung der Antriebsstrangkomponenten bezüglich des Leistungsflusses in

- Parallele Hybride
- Serielle Hybride und
- Kombinierte/Leistungsverzweigte Hybride

unterteilen [200, 138, 90, 188]. Abbildung 2.1 zeigt mögliche Antriebstopologien.

Ein *paralleler* Hybrid kann sowohl vom Verbrennungsmotor, vom Elektromotor als auch durch Kombination beider Energiewandler (Leistungsüberlagerung) angetrieben werden. Je nach Anordnung der E-Maschine im Antriebsstrang werden verschiedene Konzepte unterschieden [136]. Die Leistungsüberlagerung beider Motoren kann über eine Addition der Drehmomente, der Drehzahlen oder der Zugkräfte realisiert werden und erlaubt eine kleinere Dimensionierung des Verbrennungsmotors<sup>1</sup> ohne Fahrleistungseinbußen gegenüber dem konventionellen Antrieb oder eine Leistungssteigerung bei gleichbleibenden Verbrennungsmotor. Abbildung 2.1 zeigt eine parallele Hybridtopologie mit der E-Maschine an der Kurbelwelle und einer Trennkupplung zur vollständigen Abkopplung des Verbrennungsmotors vom Antriebsstrang für einen rein elektrischen Fahrbetrieb.

---

<sup>1</sup>Downsizing

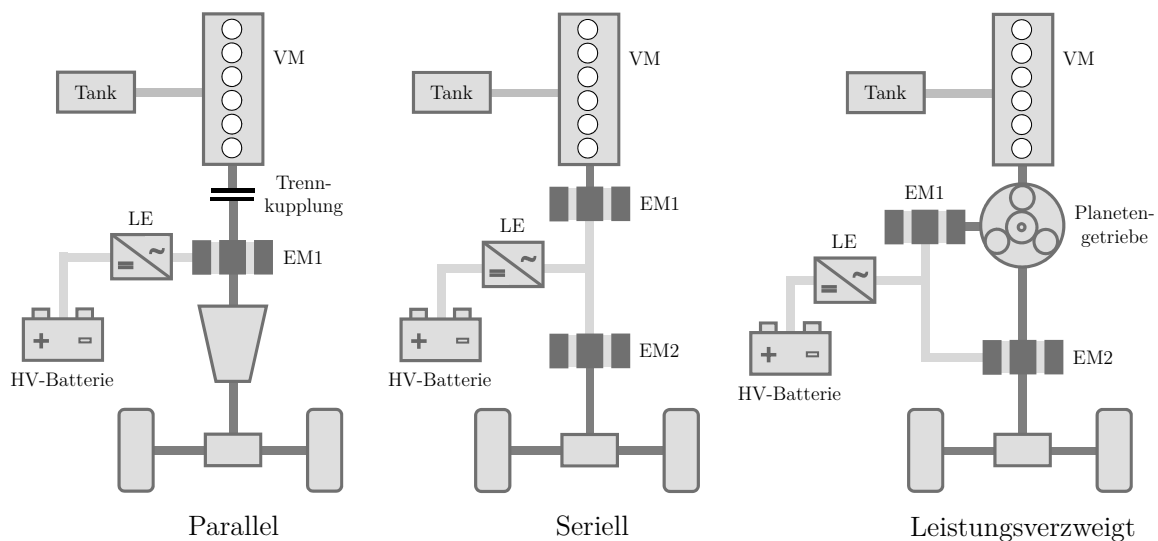


Abbildung 2.1: Mögliche Antriebstopologien für Hybridelektrofahrzeuge

*Serielle* Hybride besitzen mindestens zwei E-Maschinen und weisen keine mechanische Kopplung zwischen Verbrennungsmotor und den Antriebsrädern auf. Während eine E-Maschine für den Antrieb des Fahrzeugs bzw. die Rekuperation genutzt wird, dient die zweite E-Maschine lediglich als Generator zur Erzeugung elektrischer Energie (vgl. Abbildung 2.1). Der Verbrennungsmotor kann dadurch stationär im wirkungsgradoptimalen Bereich betrieben werden, solange die elektrische Antriebsleistung bereitgestellt werden kann. Durch hohe Wirkungsgradverluste aufgrund der mehrfachen Energieumwandlung ist die serielle Topologie im PKW-Bereich bisher kaum verbreitet.

Der *leistungsverzweigte* Hybrid ist eine Mischform aus serieller und paralleler Topologie. Ein Planetenradgetriebe teilt die Verbrennungsmotorleistung auf einen mechanischen Pfad und einen elektrischen Pfad auf.<sup>2</sup> Die E-Maschinen ermöglichen bei dieser Topologie die Realisierung eines elektrisch stufenlos verstellbaren Getriebes<sup>3</sup>, wodurch der Betriebspunkt des Verbrennungsmotors frei wählbar ist und zusätzlich auf ein konventionelles Getriebe verzichtet werden kann. Da ein Teil der mechanischen Leistung direkt auf die Antriebsräder übertragbar ist (paralleles Prinzip), sind bessere Wirkungsgrade im Vergleich zu den seriellen Konzepten erzielbar. Allerdings muss ein Teil der Leistung über den elektrischen Pfad (serielles Prinzip) gewandelt werden, was insbesondere bei hohen Geschwindigkeiten den Wirkungsgrad verschlechtert [149].

<sup>2</sup>Eine weitere Mischform ist der *kombinierte* Hybrid, welcher durch eine Kupplung zwischen den beiden E-Maschinen zwischen seriellen und parallelen Betrieb wechseln kann [134].

<sup>3</sup>eCVT = Electric Continuous Variable Transmission

## 2.2 Hybridantriebsfunktionen

Im Vergleich zu konventionellen Fahrzeugen ergeben sich aufgrund der zusätzlichen Antriebsstrangkomponenten für ein Hybridelektrofahrzeug folgende Betriebsarten (vgl. [90, 149]):

- *Elektrisches Fahren*

Das Fahrzeug kann in diesem Betriebsmodus emissionsfrei fahren. Die E-Maschine stellt das gesamte Antriebsmoment während der Verbrennungsmotor vom Antriebsstrang abgekoppelt und gestoppt ist. Die notwendige Energie wird durch die Traktionsbatterie bereit gestellt, welche zusätzlich die elektrifizierten Nebenaggregate versorgen muss (siehe Abschnitt 3.1). Die Entscheidung des elektrischen Fahrens wird primär von dem Ziel der Kraftstoffminimierung beeinflusst. Weitere Einflussfaktoren im Fahrzeug sind z.B. der Ladezustand (SOC)<sup>4</sup> der Hochvoltbatterie, Systemgrenzen der einzelnen Komponenten, der Fahrkomfort oder die Emissionierung.

- *Lastpunktverschiebung*

Das Ladezustandsmanagement<sup>5</sup> steuert über die Lastpunktverschiebung die Leistungsaufnahme bzw. -abgabe der E-Maschine bei laufendem Verbrennungsmotor und regelt somit den Ladezustand der Traktionsbatterie. Hierbei wird zwischen einer Lastpunktanhebung (LPAn) und einer Lastpunktabsenkung (LPAb)<sup>6</sup> unterschieden. Das Abtriebsmoment sowie die Drehzahl des Verbrennungsmotors werden nicht beeinflusst. Bei einer Lastpunktanhebung stellt der Verbrennungsmotor mehr Drehmoment zur Verfügung als zum Vortrieb des Fahrzeugs notwendig ist. Das überschüssige Moment wird generatorisch durch die E-Maschine in elektrische Energie umgesetzt und zum Laden der Traktionsbatterie genutzt. Umgekehrt arbeitet die E-Maschine bei einer Lastpunktabsenkung im motorischen Betrieb und entlädt dabei die Hochvoltbatterie. Der Lastpunkt des Verbrennungsmotors ist abgesenkt, wodurch dieser weniger Kraftstoff verbraucht. Bei der Lastpunktanhebung kann zwischen Fahrbetrieb und Fahrzeugstillstand mit VM-Leerlauf differenziert werden.

- *Verbrennungsmotorischer Betrieb*

Der Antriebswunsch wird alleine vom Verbrennungsmotor umgesetzt und eine

---

<sup>4</sup>State of Charge

<sup>5</sup>SOC-Regelung

<sup>6</sup>Assist



Lastpunktverschiebung findet nicht statt.<sup>7</sup>

- *Rekuperation*

In Verzögerungsphasen kann ein Großteil der kinetischen Energie des Fahrzeugs zurückgewonnen werden. Die E-Maschine arbeitet im Generatorbetrieb und versorgt das Fahrzeugbordnetz bzw. speist die Hochvoltbatterie. Die Rekuperationsleistung ist abhängig von der Dimensionierung des elektrischen Systems aber auch von den Grenzen der Fahrstabilität. Ist der Verbrennungsmotor während der Rekuperation an den Antriebsstrang gekoppelt, reduziert sich das mögliche Rekuperationspotenzial aufgrund des wirksamen Schlepplmoments. Zusätzlich ist zwischen Bremsrekuperation (bei betätigten Bremspedal) und Schleppekuperation (oder auch Schubrekuperation) zu unterscheiden. Letztere dient der Simulation des Schlepplverhaltens des Verbrennungsmotors im elektrischen Schubbetrieb durch ein äquivalentes generatorisches E-Maschinenmoment. Im Vergleich zur Lastpunktanhebung kann der Traktionsspeicher mit der Rekuperation deutlich effizienter geladen werden da kein zusätzlicher Kraftstoff benötigt wird.

- *Motor-Start-Stopp*

Das Fahrzeug befindet sich im Stillstand und der Verbrennungsmotor sowie die E-Maschine sind abgeschaltet. Die Grundverluste des verbrennungsmotorischen Leerlaufs können dadurch vermieden werden. Das Fahrzeugbordnetz bzw. die Komfortverbraucher werden durch den Hochvoltspeicher versorgt.

- *Boosten*

Die Antriebsleistung des Fahrzeugs kann durch das Boosten temporär erhöht werden. Dabei stellt die E-Maschine ein zusätzliches motorisches Moment für den Vortrieb bereit, während der Verbrennungsmotor bereits sein derzeit maximal mögliches Moment abgibt. Neben einer Erweiterung der Fahrleistung über die Vollastkennlinie des Verbrennungsmotors hinaus (Stationärboost) kann auch das dynamische Ansprechverhalten verbessert werden (Instationärboost).

- *Segeln*

Beim Segeln sind sowohl der gestoppte Verbrennungsmotor als auch die E-Maschine von der Abtriebsseite abgekoppelt. Das Fahrzeug wird lediglich durch die verbleibenden Schlepplverluste im Antriebsstrang und durch die Fahrwiderstände verzögert.

---

<sup>7</sup>Hierzu zählt auch der Leerlaufbetrieb des Verbrennungsmotors ohne Lastpunktanhebung.

## 2.3 Betriebsstrategien in Hybridfahrzeugen

Die Betriebsstrategie koordiniert das Zusammenspiel zwischen den mechanischen und elektrischen Antriebsstrangkomponenten bei der Umsetzung der Wunschvorgaben des Fahrers unter Berücksichtigung von Umweltbedingungen und physikalischer Systemgrenzen sowie unter Einhaltung der gesetzlichen Bestimmungen. Hierbei erfolgt eine maßgebliche Beeinflussung der Charakteristik des Fahrzeugs hinsichtlich:

- Fahrleistung
- Fahrdynamik
- Kraftstoffverbrauch
- Emissionen
- Fahrbarkeit
- Komfort und
- Lebensdauer.

Zu den für die Betriebsstrategie relevanten Fahrervorgaben zählen unter anderem [90]:

- Fahrpedal
- Bremspedal
- Fahrtrichtung
- Gangwahlschalter
- Fahrmodi-Schalter und
- Komfortverbraucher.

Darüber hinaus sind Umweltbedingungen wie z.B. Umgebungstemperatur, Streckentopografie oder die Verkehrssituation zu berücksichtigen. Zusätzlich können auch Streckeninformationen des Navigationssystems mit einbezogen werden [144, 187, 203]. Physikalische Systemgrenzen ergeben sich im Wesentlichen aus den einzelnen Komponentengrenzen bezüglich Temperatur, Leistung, Drehmoment, Drehzahl, usw. sowie durch sicherheitsrelevante Einschränkungen (z.B. maximal zulässiges Rekuperationsmoment).

Im Vergleich zum konventionellen Antrieb ergeben sich durch die Hybridfahrzeugtopologie zusätzliche Freiheitsgrade, wie z.B. die Verteilung des Antriebsmoments auf die jeweiligen Energiewandler, die Steuerung der Lastpunktverschiebung am Verbrennungsmotor oder die Entscheidung zum elektrischen Fahren. Aufgabe der Betriebsstrategie ist es, den Zielkonflikt zwischen den teilweise konträren Zielgrößen aufzulösen.

In der Literatur existiert eine Vielzahl von Ansätzen zur Betriebsführung von Hybridelektrofahrzeugen. Weit verbreitet sind dabei heuristische<sup>8</sup> Verfahren basierend auf Regeln und Fuzzy-Logik [34, 207, 106, 213], Spieltheorie [180, 54] oder neuronalen Netzen [98, 131]. Die Verfahren sind in der Regel einfach und übersichtlich und werden aufgrund des vergleichsweise geringen Rechenzeitbedarfs für Echtzeitanwendungen bevorzugt. Das Optimum der jeweiligen Problemstellung kann allerdings nicht garantiert werden und ist stark abhängig von der Güte der aufgestellten Regeln. Häufig bildet eine Offline-Optimierung die Basis für die Ableitung und Parametrierung einer geeigneten heuristischen Betriebsstrategie [214].

Die Ermittlung der optimalen Betriebsführung für einen gegebenen Fahrzyklus kann offline z.B. mithilfe der Dynamischen Programmierung [172, 183, 151, 3], Mixed-Integer linearen Programmierung [160], Lagrange/Hamilton-Optimierung [52] oder durch Anwendung direkter Verfahren erfolgen [110]. Nachteilig ist der oft hohe Rechenaufwand, welcher exponentiell mit der Anzahl an Zustands- und Steuergrößen ansteigt.

Für den Online-Einsatz existieren verschiedene Optimierungsansätze [118, 12, 99, 9, 171, 101]. Um jedoch im realen Fahrbetrieb die optimalen Steuertrajektorien z.B. für die Vorgabe der E-Maschinenleistung bestimmen zu können, ist eine Prädiktion des zukünftigen Fahrprofils notwendig. Viele Online-Verfahren definieren Kostenfunktionen oder verwenden Äquivalenzwerte (ECMS)<sup>9</sup>, z.B. für die elektrische oder die chemische Energie. Das Ziel ist in diesem Fall immer die Minimierung der Kostenfunktion bzw. der energetischen Verluste im Antriebsstrang und damit eine Sollvorgabe der Betriebspunkte der einzelnen Systemkomponenten [170, 132, 2, 196, 32, 142, 111, 104]. Im Gegensatz zu den heuristischen Ansätzen werden deutlich weniger Einstellparameter benötigt. Jedoch sind die berechneten Betriebsstrategien bei unbekanntem Fahrprofilen ebenfalls nur suboptimal [89]. In vielen Fällen können Streckeninformationen zur Prädiktion oder Adaption genutzt werden und so eine bestehende Betriebsstrategie sinnvoll ergänzen [187, 204, 203, 33].

---

<sup>8</sup>zu griech. *heurískein* = finden, entdecken: Lehre, Wissenschaft von den Verfahren, Probleme zu lösen; methodische Anleitung, Anweisung zur Gewinnung neuer Erkenntnisse [60]

<sup>9</sup>Equivalent consumption minimization strategies

## 2.4 Multikriterielle Optimierung

Im Folgenden wird auf die Grundlagen der multikriteriellen Optimierung und im Speziellen auf genetische Algorithmen eingegangen. Letztere sollen für die Betriebsstrategieoptimierung im Rahmen dieser Arbeit verwendet werden.

### 2.4.1 Einordnung und Definitionen

Bei einer multikriteriellen Optimierung<sup>10</sup> werden mehrere Zielgrößen durch einen Vektor von Entscheidungsvariablen unter Beachtung von Nebenbedingungen gleichzeitig minimiert bzw. maximiert. Die Zielkriterien sind dabei häufig konträr, so dass kein Lösungsvektor gefunden werden kann der optimal bezüglich aller Zielkriterien ist. Es existiert eine Lösungsmenge von optimalen Alternativen aus dem der Entscheidungsfinder wählen kann [38].

Die Entscheidungs- oder Designvariablen<sup>11</sup> werden durch einen n-dimensionalen Vektor  $\mathbf{x}$  beschrieben:

$$\mathbf{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = [x_1, x_2, \dots, x_n]^T \quad (2.1)$$

Die Optimierungsvariablen können dabei sowohl kontinuierlich als auch diskret vorliegen.

Die Güte einer Optimierung kann in der Regel durch eine skalare Maßzahl oder eine Gütefunktion  $f(\mathbf{x})$  definiert werden [139]. Während bei einem Einzielloptimierungsproblem lediglich eine Zielfunktion als Gütekriterium dient, existieren bei einem Mehrzielloptimierungsproblem mindestens zwei Zielfunktionen, welche den Gütefunktionsvektor  $\mathbf{f}(\mathbf{x})$  bilden.

$$\mathbf{f}(\mathbf{x}) = \begin{bmatrix} f_1(\mathbf{x}) \\ f_2(\mathbf{x}) \\ \vdots \\ f_m(\mathbf{x}) \end{bmatrix} = [f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})]^T \quad (2.2)$$

Ein multikriterielles Optimierungsproblem kann mathematisch wie folgt beschrieben

---

<sup>10</sup>auch Mehrzielloptimierung oder Vektoroptimierung

<sup>11</sup>auch als Optimierungsparameter bezeichnet

werden (vgl. [43]):

$$\begin{aligned}
 & \text{Minimiere } \mathbf{f}(\mathbf{x}) \\
 & \quad \text{mit } \mathbf{g}(\mathbf{x}) \geq 0 \\
 & \quad \text{und } \mathbf{h}(\mathbf{x}) = 0 \\
 & \text{wobei gilt } \mathbf{x} \in \mathbb{R}^n, \mathbf{f}(\mathbf{x}) \in \mathbb{R}^m, \mathbf{g}(\mathbf{x}) \in \mathbb{R}^j, \mathbf{h}(\mathbf{x}) \in \mathbb{R}^k
 \end{aligned} \tag{2.3}$$

Gesucht wird der Vektor  $\mathbf{x}^* = [x_1^*, x_2^*, \dots, x_n^*]^T$ , welcher die Vektorfunktion  $\mathbf{f}(\mathbf{x})$  unter Einhaltung der  $j$  Ungleichungsnebenbedingungen  $\mathbf{g}(\mathbf{x})$  und  $k$  Gleichungsnebenbedingungen  $\mathbf{h}(\mathbf{x})$  minimiert. Im Rahmen dieser Arbeit wird stets von einem Minimierungsproblem ausgegangen, was nach Gleichung 2.4 Maximierungsprobleme nicht ausschließt und damit keine Einschränkung darstellt.

$$\min \{\mathbf{f}(\mathbf{x})\} = -\max \{-\mathbf{f}(\mathbf{x})\} \tag{2.4}$$

Die Menge aller Punkte  $\mathbf{x} \in \mathbb{R}^n$ , welche die Nebenbedingungen erfüllen, wird als zulässiger Bereich  $\Omega$ <sup>12</sup> definiert:

$$\Omega := \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{g}(\mathbf{x}) \geq 0 \wedge \mathbf{h}(\mathbf{x}) = 0\} \tag{2.5}$$

Jeder Punkt des zulässigen Bereichs  $\mathbf{x} \in \Omega$  ist eine zulässige Lösung des Optimierungsproblems. Der Gütefunktionsvektor,  $\mathbf{f}(\mathbf{x}) : \Omega \rightarrow Z$ , bildet jede zulässige Lösung  $\mathbf{x} = [x_1, x_2, \dots, x_n]^T$  als Vektor  $\mathbf{z} = [z_1, z_2, \dots, z_m]^T$  in den Zielfunktionsraum  $Z$  ab. Abbildung 2.2 veranschaulicht den Zusammenhang zwischen Entscheidungsvariablenraum und Zielfunktionsraum für  $n = 2$  und  $m = 2$ .

Im Gegensatz zur einkriteriellen Optimierung werden bei der multikriteriellen Optimierung mehrere, teils konkurrierende Ziele optimiert. Folglich existiert nicht nur eine optimale Lösung, sondern vielmehr eine Menge an Kompromisslösungen. Diese Lösungsmenge kann durch die Pareto-optimale Menge, deren Theorie auf den italienischen Ökonom Vilfredo Pareto zurück geht, beschrieben werden [140]. Im Folgenden werden die wichtigsten Begriffe der Pareto-Terminologie definiert und erläutert. Diese orientieren sich an den Ausführungen zum Pareto-Konzept in [193, 192, 43, 38].

---

<sup>12</sup>auch als Suchraum oder Variablenraum bezeichnet




Abbildung 2.2: Entscheidungsvariablenraum und zugehöriger Zielfunktionsraum

**Definition 1 (Pareto-Optimalität)** Eine Lösung  $\mathbf{x}_1 \in \Omega$  ist Pareto-optimal dann und nur dann, wenn kein Vektor  $\mathbf{x}_2 \in \Omega$  existiert, für den  $\mathbf{z} = \mathbf{f}(\mathbf{x}_2) = [f_1(\mathbf{x}_2), f_2(\mathbf{x}_2), \dots, f_m(\mathbf{x}_2)]^T$  den Zielfunktionsvektor  $\mathbf{u} = \mathbf{f}(\mathbf{x}_1) = [f_1(\mathbf{x}_1), f_2(\mathbf{x}_1), \dots, f_m(\mathbf{x}_1)]^T$  dominiert.

**Definition 2 (Pareto-Dominanz)** Ein Vektor  $\mathbf{z}$  dominiert einen Vektor  $\mathbf{u}$ ,  $\mathbf{z} \preceq \mathbf{u}$  dann und nur dann, wenn  $\forall i \in \{1, 2, \dots, n\} : z_i \leq u_i \wedge \exists i \in \{1, 2, \dots, n\} : z_i < u_i$ .

Ein Zielfunktionsvektor  $\mathbf{z}$  dominiert einen anderen Vektor  $\mathbf{u}$ , wenn letzterer in keinem Zielkriterium besser und in mindestens einem Kriterium schlechter ist als  $\mathbf{z}$ . Folglich dominiert eine Lösung  $\mathbf{x}$  eine andere Lösung  $\mathbf{x}^*$ , wenn der Zielfunktionsvektor  $\mathbf{f}(\mathbf{x})$  den Vektor  $\mathbf{f}(\mathbf{x}^*)$  dominiert.

**Definition 3 (Pareto-optimale Menge)** Die Pareto-optimale Menge  $P^*$  als Teilmenge von  $\Omega$  ist definiert als:

$$P^* := \{\mathbf{x}_1 \in \Omega \mid \nexists \mathbf{x}_2 \in \Omega : \mathbf{f}(\mathbf{x}_2) \preceq \mathbf{f}(\mathbf{x}_1)\} \quad (2.6)$$

Pareto-optimal ist eine zulässige Lösung also dann, wenn es keinen weiteren Lösungsvektor gibt, der ein Zielkriterium verbessert, ohne gleichzeitig mindestens ein anderes zu verschlechtern. Die dazugehörigen Zielfunktionsvektoren werden als *nicht-dominiert* bezeichnet und bilden im Zielfunktionsraum die Pareto-Front.

**Definition 4 (Pareto-Front)** Die Pareto-Front  $PF^*$  eines multikriteriellen Optimierungsproblems mit einer Pareto-optimalen Menge  $P^*$  ist definiert als:

$$PF^* := \{ \mathbf{z} = \mathbf{f}(\mathbf{x}) \mid \mathbf{x} \in P^* \} \quad (2.7)$$

Abbildung 2.3 veranschaulicht beispielhaft die Pareto-Front (durchgezogene Linie) als Teilmenge des Zielfunktionsraums  $Z$  für zwei Zielfunktionen. Die Punkte 1 – 3 werden

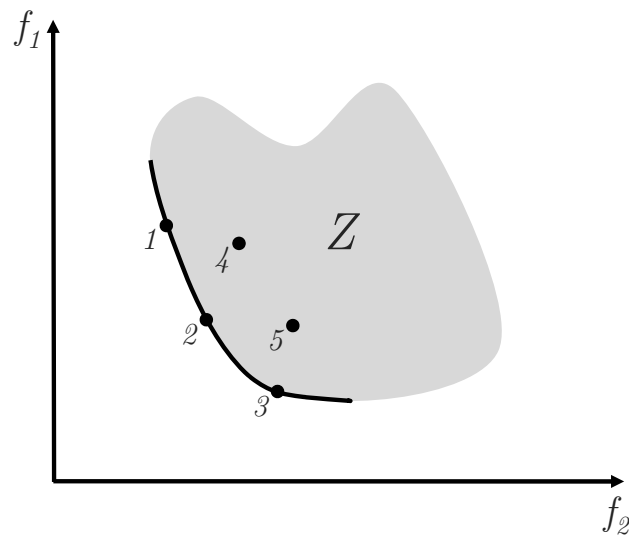


Abbildung 2.3: Darstellung der Pareto-Front als Teilmenge des Zielfunktionsraums

von keinem anderen Punkt des Zielfunktionsraums dominiert und gehören folglich zur Pareto-Front. Punkt 4 und 5 werden im Beispiel von Punkt 2 bzw. 3 dominiert.

Bedingt durch die Vielzahl an optimalen Alternativlösungen muss eine Entscheidung darüber getroffen werden, welcher Parametersatz der Pareto-optimalen Menge den besten Kompromiss bezüglich aller Zielkriterien für die betrachtete Aufgabenstellung bietet. Die Auswahl des Entscheidungsfinders stellt gewissermaßen eine subjektive Abwägung der einzelnen Lösungen dar.

## 2.4.2 Lösungsmethoden

Zur Lösung multikriterieller Optimierungsprobleme existieren verschiedenste Ansätze. Folgende Einteilung klassifiziert die Methoden nach der Art der Lösungsgenerierung bzw. -auswahl (vgl. [43, 38]):

**No-preference Ansatz:** Dieser Ansatz benötigt keinerlei Informationen bezüglich der

Wichtung der einzelnen Zielfunktionen. Für die Berechnung wird eine Heuristik verwendet, welche lediglich eine einzelne optimale Lösung ausgibt und damit keinen Eingriff eines Entscheidungsfinders benötigt.

**A-posteriori Ansatz:** A-posteriori Methoden generieren iterativ eine Approximationsmenge Pareto-optimaler Lösungen. Der Entscheidungsfinder wählt anschließend eine Lösung aus der Menge optimaler Alternativen aus.

**A-priori Ansatz:** A-priori Ansätze verlangen nach einer Festlegung der Präferenzen bezüglich der Zielfunktionen vor der eigentlichen Lösungsfindung. Als Ergebnis erhält der Nutzer üblicherweise eine optimale Lösung. Weitere Lösungen können durch veränderte Präferenzen generiert werden.

**Progressiver Ansatz:** Progressive oder interaktive Methoden beziehen den Nutzer während des Optimierungsprozesses mit ein. Ausgehend von einer gefundenen Lösungsmenge kann der Nutzer z.B. Lösungen eliminieren oder den Suchraum eingrenzen. Nachteilig ist die dauerhafte Präsenz des Nutzers während des Optimierungsprozesses.

Im Folgenden werden die am häufigsten verwendeten Methoden vorgestellt und erläutert.

### Methode der gewichteten Summe

Die Methode der gewichteten Summe<sup>13</sup> überführt den ursprünglichen Zielfunktionsvektor mithilfe von Gewichtungsfaktoren in eine skalare Zielfunktion. Damit ergibt sich aus Gleichung 2.3 ein einkriterielles Optimierungsproblem der Form [37, 43]:

$$\begin{aligned} \text{Minimiere } f(\mathbf{x}) &= \sum_{i=1}^m w_i f_i(\mathbf{x}) \\ \text{mit } \mathbf{x} &\in \Omega \\ \text{und } \forall i \in \{1, 2, \dots, m\} &: w_i \geq 0 \wedge \\ &\exists i \in \{1, 2, \dots, m\} : w_i > 0. \end{aligned} \tag{2.8}$$

Da die Zielgrößen in der Regel unterschiedliche Größenordnungen aufweisen werden diese normiert, so dass sie bezüglich ihrer Wertebereiche gleich gewichtet sind. Die Gewichtungsfaktoren  $w_i \in \{0, 1\}$  werden anschließend so gewählt, dass deren Summe 1

---

<sup>13</sup>weighted sum method



ergibt  $\sum_{i=1}^m w_i = 1$ . Durch Variation der Faktoren  $w_i$  können Pareto-optimale Lösungen generiert werden. Für konvexe Vektoroptimierungsprobleme mit einer Pareto-optimalen Lösung  $\mathbf{x}^*$  existiert immer ein positiver Gewichtsvektor  $\mathbf{w} \neq 0$ , so dass  $\mathbf{x}^*$  auch eine Lösung von Gleichung 2.8 ist. Folglich kann für Probleme mit konvexen Pareto-Fronten jeder Punkt der Pareto-Menge durch geeignete Wahl der Gewichtungsfaktoren bestimmt werden [127].

**Definition 5 (Konvexität)** *Eine Funktion  $f(\mathbf{x})$  mit  $\mathbf{x} \in \mathbb{R}^n$  ist eine konvexe Funktion, wenn für zwei beliebige Vektoren  $\mathbf{x}_1$  und  $\mathbf{x}_2$  und  $\lambda \in \{0, 1\}$  gilt:*

$$f(\lambda\mathbf{x}_1 + (1 - \lambda)\mathbf{x}_2) \leq \lambda f(\mathbf{x}_1) + (1 - \lambda)f(\mathbf{x}_2) \quad (2.9)$$

*Eine Menge an Punkten im  $n$ -dimensionalen Raum ist eine konvexe Menge, wenn sich die Verbindungslinie aller möglichen Punktepaare  $(\mathbf{x}_1, \mathbf{x}_2)$  ebenfalls komplett in der Menge befindet.*

$$\mathbf{x} = \lambda\mathbf{x}_1 + (1 - \lambda)\mathbf{x}_2 \quad (2.10)$$

*Ein multikriterielles Optimierungsproblem ist konvex, wenn alle Zielfunktionen und der Entscheidungsvariablenraum konvex sind (oder alle  $\mathbf{g}(\mathbf{x})$  sind nicht-konvex und  $\mathbf{h}(\mathbf{x})$  sind linear) [43].*

Die Wahl von  $w_i$ , wodurch eine Präferenz der Zielgrößen definiert wird, hat einen großen Einfluss auf das Ergebnis. Allerdings führen homogen verteilte Gewichtungsfaktoren nicht zwingend zu einer Lösungsmenge mit einer dazugehörigen homogenen Pareto-Front im Zielfunktionsraum. Um gezielt bestimmte Bereiche im Zielfunktionsraum abzudecken ist es u.U. schwierig einen korrespondierenden Gewichtsvektor  $\mathbf{w}$  zu finden. Ferner können verschiedene Gewichtungsfaktoren zum selben Lösungsvektor führen.

Abbildung 2.4 veranschaulicht im linken Bild beispielhaft die Anwendung der Methode für einen konvexen Zielfunktionsraum. Die Punkte 1–4 stellen dabei die Zielfunktionswerte für unterschiedliche Gewichtungsfaktoren dar und lassen sich als Berührungspunkte einer Tangente an den Suchraum interpretieren. Deren Anstieg ist dabei abhängig von der Wahl der Gewichtungsfaktoren. Im rechten Bild zeigt sich ein Nachteil der Methode, die bei nicht-konvexen Problemen nicht alle Pareto-optimale Lösungen bestimmen kann. So kann im Beispiel kein Punkt der Pareto-Front zwischen Punkt 6 und 7 nach Gleichung 2.8 ermittelt werden.




Abbildung 2.4: Anwendung der Methode der gewichteten Summe bei konvexer (links) und nicht-konvexer (rechts) Menge im Zielfunktionsraum

### $\epsilon$ -Constraint Methode

Die  $\epsilon$ -Constraint Methode<sup>14</sup> erlaubt auch bei nicht-konvexen Optimierungsproblemen alle Pareto-optimalen Lösungen zu bestimmen. Dabei wird nur eine Zielfunktion  $f_\mu(\mathbf{x})$  minimiert, während die anderen Zielfunktionen als Nebenbedingungen formuliert werden. Aus Gleichung 2.3 wird in diesem Fall [37, 43]:

$$\begin{aligned}
 &\text{Minimiere } f_\mu(\mathbf{x}) \\
 &\text{mit } \mathbf{x} \in \Omega \\
 &\text{und } f_i(\mathbf{x}) \leq \epsilon_i \text{ für } i = 1, 2, \dots, m \text{ und } i \neq \mu
 \end{aligned} \tag{2.11}$$

Der Parameter  $\epsilon_i$  stellt eine beliebige obere Schranke der  $m$ -ten Zielfunktion dar. Die Lösung von Gleichung 2.11 ist Pareto-optimal für jeden beliebigen Vektor  $\epsilon = (\epsilon_1, \dots, \epsilon_{\mu-1}, \epsilon_{\mu+1}, \dots, \epsilon_m)^T$  [127]. Durch die geeignete Wahl von  $\epsilon$  kann also jeder Pareto-optimale Punkt der Lösungsmenge ermittelt werden, und zwar unabhängig davon, ob der Zielfunktionsraum konvex oder nicht-konvex ist.

In Abbildung 2.5 ist ein Beispiel der Methode für zwei Zielfunktionen mit nicht-konvexem Zielfunktionsraum dargestellt. Im Beispiel ist  $f_1(\mathbf{x})$  die zu minimierende Funktion, während  $f_2(\mathbf{x})$  durch verschiedene Grenzen  $\epsilon_2$  beschränkt wird  $f_2(\mathbf{x}) \leq \epsilon_2$ . Die Lösung des Optimierungsproblems hängt stark von der Wahl des Vektors  $\epsilon$  ab. Dieser muss so gewählt werden, dass er innerhalb des Wertebereichs der einzelnen

<sup>14</sup>häufig auch trade-off Methode




Abbildung 2.5: Anwendung der  $\epsilon$ -Constraint Methode bei nicht-konvexer Menge im Zielfunktionsraum

Zielfunktionen liegt. Ähnlich wie bei der Methode der gewichteten Summe kann durch die Variation von  $\epsilon$  eine Menge an Pareto-optimalen Lösungen generiert werden. Im Beispiel wird für  $\epsilon_2^a$  keine Lösung gefunden. Für  $\epsilon_2^d$  erhält man den rechten Endpunkt 3 der Paretofront, da  $f_2(\mathbf{x})$  quasi nicht beschränkt wird. Die Verwendung von  $\epsilon_2^c$  ermöglicht eine Lösung (Punkt 2) im nicht-konvexen Zielfunktionsraum.

### Methode der gewichteten Metrik

Als weitere Möglichkeit der Zusammenfassung von mehreren Zielfunktionen zu einer Zielfunktion sind gewichtete Metriken aufzuführen. Für nicht-negative Gewichte  $p$  wird das gewichtete Distanzmaß  $l_p(\mathbf{x})$  einer beliebigen Lösung  $\mathbf{x}$  von einem idealen Zielfunktionsvektor  $\mathbf{z}^*$  minimiert [43]:

$$\begin{aligned} \text{Minimiere } l_p(\mathbf{x}) &= \left( \sum_{i=1}^m w_i |f_m(\mathbf{x}) - \mathbf{z}_i^*|^p \right)^{\frac{1}{p}} \\ &\text{mit } \mathbf{x} \in \Omega \\ &\text{und } p \in \{1, \infty\} \end{aligned} \tag{2.12}$$

**Definition 6 (Idealer Zielfunktionsvektor)** Die  $m$ -te Komponente eines idealen Zielfunktionsvektors  $\mathbf{z}^*$  ist die Lösung des folgenden Problems:

$$\begin{aligned} & \text{Minimiere } f_m(\mathbf{x}) \\ & \text{mit } \mathbf{x} \in \Omega \end{aligned} \tag{2.13}$$

Für jede der  $m$  Zielfunktionen existiert eine optimale Lösung. Der ideale Zielfunktionsvektor setzt sich aus den einzelnen optimalen Zielfunktionswerten zusammen [43].

$$\mathbf{z}^* = \mathbf{f}^* = [f_1^*, f_2^*, \dots, f_m^*]^T \tag{2.14}$$

Im Allgemeinen ist der korrespondierende Lösungsvektor  $\mathbf{x}^*$  nicht existent, da hierfür alle Zielfunktionen  $f_m(\mathbf{x})$  das gleiche Minimum aufweisen müssten.

Für  $p = 1$  ergibt sich aus Gleichung 2.12 der Ansatz der gewichteten Summe (vgl. Gleichung 2.8). Für  $p = 2$  wird die gewichtete euklidische Distanz von jedem Punkt des Zielraums zum idealen Zielfunktionsvektor minimiert. Werden große Werte für  $p$  verwendet ( $p \rightarrow \infty$ ) reduziert sich das Problem auf die Minimierung der größten Abweichung, auch gewichtetes Tschebyscheff-Problem genannt. Mit Letzterem können nach [127] alle Pareto-optimalen Lösungen gefunden werden. Allerdings benötigt man zur Bestimmung des idealen Zielfunktionsvektors die Minima der einzelnen  $m$  Zielfunktionen. Weiterhin ist eine Normierung der Zielfunktionen zweckmäßig, was Informationen über die jeweiligen Wertebereiche bedingt [43].

## Nutzenfunktionsmethode

Die Methode beruht auf der Maximierung einer benutzerdefinierten Nutzenfunktion, welche  $m$  Zielfunktionen auf eine Funktion abbildet  $N : \mathbb{R}^m \rightarrow \mathbb{R}$ :

$$\begin{aligned} & \text{Minimiere } N(\mathbf{f}(\mathbf{x})) \\ & \text{mit } \mathbf{x} \in \Omega \end{aligned} \tag{2.15}$$

Ist die Nutzenfunktion im gesamten zulässigen Bereich definiert und streng monoton fallend, so ist das Maximum  $\mathbf{f}^*$  aus  $N$  Pareto-optimal [43, 127]. Jede berechnete Lösung ist dabei von den Parametern der Nutzenfunktion abhängig, wobei nur eine Lösung pro Berechnung möglich ist. Durch die Variation der Parameter können weitere Lösungen gefunden werden.

## Goal Programming

Beim Goal Programming werden für jede der  $m$  Zielfunktionen konkrete Zielwerte (goals)  $T_i$  vorgegeben, die als zusätzliche Nebenbedingungen definiert sind. Anschließend wird der Abstand zwischen erreichten und vorgegebenen Zielwerten minimiert [37]:

$$\begin{aligned} \text{Minimiere } & \sum_{i=1}^m |f_i(\mathbf{x}) - T_i| \\ & \text{mit } \mathbf{x} \in \Omega \end{aligned} \quad (2.16)$$

Wird der Zielwertvektor  $\mathbf{T}$  innerhalb des möglichen Zielfunktionsraums  $Z$  gewählt, so ist das Ergebnis von Gleichung 2.16 die zulässige Lösung  $\mathbf{x}$ , für die gilt:

$$\mathbf{f}(\mathbf{x}) = \mathbf{T} \quad (2.17)$$

Wenn der vorgegebene Zielwertvektor außerhalb des Zielfunktionsraums liegt, kann durch Minimierung des Abstandes zum berechneten Zielwert eine Pareto-optimale Lösung gefunden werden. Das Zielkriterium in Gleichung 2.17 kann auch als Ungleichungsbedingung, d.h. der Zielwert  $f(\mathbf{x})$  ist größer oder kleiner als der vorgegebene Zielfunktionswert  $T_i$ , formuliert werden oder der Zielwert muss innerhalb eines bestimmten Intervalls liegen. Für eine Zielfunktion lässt sich das definierte Zielkriterium mithilfe der beiden nicht negativen Abstandsvariablen  $p$  und  $n$  in einer Gleichungsnebenbedingung darstellen [43]:

$$f(\mathbf{x}) - p + n = T_i \quad (2.18)$$

Abhängig von der Art der Minimierung der Abstände  $p$  und  $n$  werden verschiedene Methoden des Goal Programmings unterschieden. Beim Weighted Goal Programming wird die gewichtete Summe der Abstände minimiert:

$$\begin{aligned} \text{Minimiere } & \sum_{i=1}^m (\alpha_i p_i + \beta_i n_i) \\ & \text{mit } f_i(\mathbf{x}) - p_i + n_i = T_i \\ & \text{und } \mathbf{x} \in \Omega \\ & n_i, p_i \geq 0 \end{aligned} \quad (2.19)$$

$\alpha_i$  und  $\beta_i$  sind die Gewichtungsfaktoren für die Abstände der  $i$ -ten Zielfunktion und beeinflussen maßgeblich den Lösungsvektor. Für kleiner-gleich Zielkriterien ist  $\beta_i$  gleich Null während für größer-gleich Zielkriterien  $\alpha_i$  den Wert Null annimmt. Beim Lexico-

graphic Goal Programming werden die verschiedenen Ziele vom Entscheidungsfinder entsprechend der Wichtigkeit priorisiert. Im ersten Schritt werden lediglich die Ziele mit der höchsten Priorität bei der Optimierungsaufgabe berücksichtigt. Existieren mehrere Lösungen werden im nächsten Schritt die Zielfunktionen mit der zweithöchsten Priorität minimiert, wobei die Ziele mit der höchsten Priorität aus der vorangegangenen Optimierung als Nebenbedingung definiert werden. Der Prozess wiederholt sich mit den weiteren Zielfunktionen gemäß der Prioritätsliste bis schließlich nur noch eine einzige Lösung existiert.

Die hier vorgestellten Methoden überführen allesamt die multikriterielle Optimierungsaufgabe in ein einkriterielles Problem, welches dann mithilfe von klassischen Verfahren der nichtlinearen Optimierung gelöst werden kann. Diese lassen sich grob in drei Kategorien einteilen.

### **Deterministische Verfahren**

Klassische analytische Algorithmen werden der Gruppe der deterministischen Verfahren zugeordnet und können dabei in direkte und indirekte Verfahren unterteilt werden. Während Letztere den Gradienten der Zielfunktion zu Null setzen und die entsprechende Gleichung lösen, bewegen sich die direkten Verfahren ausgehend von einem beliebigen Startpunkt in Richtung des steilsten Gradienten (Hill-Climbing). Die Forderung nach der Differenzierbarkeit der Zielfunktion und die Gefahr lediglich lokale Optima zu finden erweisen sich als größte Nachteile [78]. Bekannte Vertreter der deterministischen Verfahren sind z.B. das Newtonverfahren, Sequential Quadratic Programming (SQP) oder das Downhill-Simplex-Verfahren. Auch die uninformierten Suchalgorithmen, wie die Tiefen- und Breitensuche (depth-first and breadth-first search) sowie heuristische, informierte Algorithmen lassen sich hier einordnen [38].

### **Enumerative Verfahren**

Der Ansatz der enumerativen Verfahren ist vergleichsweise trivial. Dabei werden innerhalb eines begrenzten Suchraums alle möglichen Lösungen nacheinander berechnet und deren Ergebnisse verglichen. Dies impliziert ebenfalls ein deterministisches Verhalten, allerdings ohne die Anwendung von Heuristiken wie bei den deterministischen Verfahren [38]. Wenn auch mit dieser Vorgehensweise sehr einfach und zuverlässig globale Optima gefunden werden können, so liegt der entscheidende Nachteil in der fehlenden Effizienz. Viele Parameterräume sind mehrdimensional und die Problemstellungen zu komplex, um alle möglichen Zielfunktionsauswertungen innerhalb akzeptabler Zeitspannen zu

berechnen.

### Stochastische Verfahren

Stochastische Verfahren wie die Zufallssuche (Random Search) werten zufällig gewählte Lösungen aus und speichern das jeweils beste Ergebnis ab. Durch die zufällige Auswahl der Parameterwerte kann ein globales Optimum nicht garantiert werden. Mit steigender Anzahl an berechneten Punkten steigt auch die Wahrscheinlichkeit, dass die derzeit beste Lösung dem globalen Optimum entspricht. Damit erhöht sich jedoch auch die Rechenzeit, weshalb die reine Zufallssuche in der Regel keine bessere Performance im Vergleich zu den enumerativen Verfahren erzielen kann [78]. Weitere Verfahren dieser Gruppe sind z.B. Stochastic Hill-Climbing, Ant Colony Optimization [58] oder Metaheuristiken wie Simulated Annealing [108] und Tabu-Search [76]. Ferner lassen sich auch die genetischen Algorithmen hier einordnen, welche im Folgenden beschrieben werden.

### 2.4.3 Genetische Algorithmen

Genetische Algorithmen (GA) sind stochastische Such- und Optimierungsverfahren, die basierend auf den Grundprinzipien der Evolutionstheorie arbeiten. Sie wurden maßgeblich von Holland [91] in den 70er Jahren entwickelt und gehören zur Gruppe der evolutionären Algorithmen, in die sich auch Evolutionsstrategien [148, 169] sowie evolutionäres und genetisches Programmieren [72, 116] einordnen lassen. Einen guten Überblick über die einzelnen Teilgebiete des evolutionären Berechnens<sup>15</sup> mit evolutionären Algorithmen gibt [10] oder [201]. Im Folgenden werden das Grundprinzip der genetischen Algorithmen sowie die für die Arbeit relevanten Operatoren erläutert.

#### Funktionsprinzip

Im Vergleich zu den meisten klassischen Lösungsmethoden multikriterieller Optimierungsprobleme arbeiten genetische Algorithmen mit mehreren Lösungen, den sog. Individuen, gleichzeitig, welche zu einer Population zusammengefasst sind. Jedes Individuum ist phänotypisch<sup>16</sup> durch seine Parameterwerte im konkreten Suchraum  $\Omega$  charakterisiert. Der Genotyp eines Individuums, das sog. Chromosom (oder auch String), ist eine codierte Darstellung des Phänotyps. Chromosomen sind in Gene unterteilt, welche die einzelnen Entscheidungsparameter des Suchraums in codierter Form (z.B. binär)

---

<sup>15</sup>evolutionary computation

<sup>16</sup>Phänotyp: Erscheinungsbild eines Organismus

enthalten. Der im Rahmen dieser Arbeit verwendete Algorithmus arbeitet mit reell codierten Variablen.

Der schematische Ablauf eines genetischen Algorithmus ist in Abbildung 2.6 dargestellt.

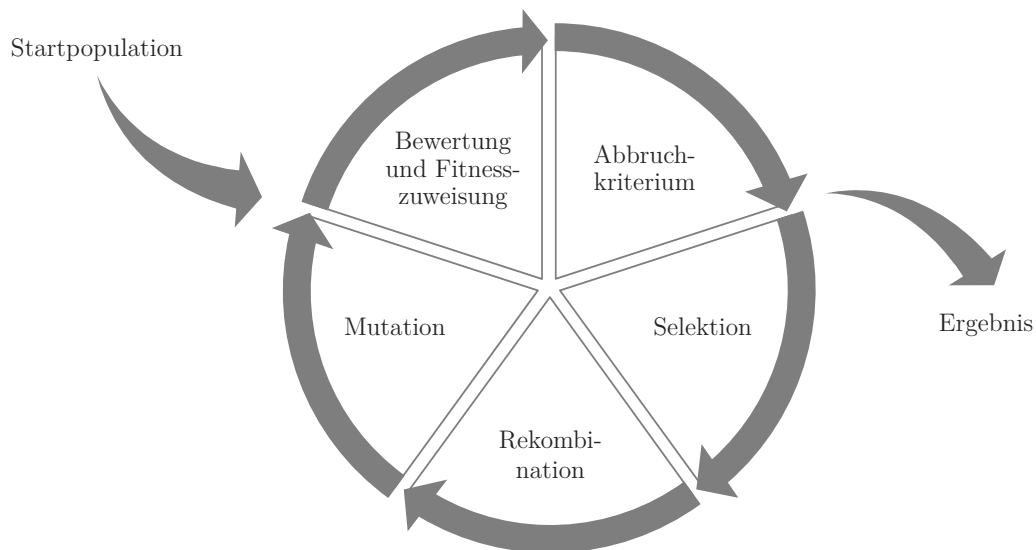


Abbildung 2.6: Ablaufschema eines genetischen Algorithmus

Ausgangspunkt ist eine Startpopulation, welche eine definierte Anzahl an zufällig verteilten Lösungen enthält. Im ersten Schritt erfolgt die Fitnesszuweisung für jedes Individuum basierend auf den berechneten Zielfunktionswerten. Je höher der Fitnesswert, desto besser ist die Anpassung des Individuums an das Optimierungsproblem. Solange die Abbruchbedingung nicht erfüllt ist, wird über die Operatoren Selektion, Rekombination und Mutation eine neue Population erzeugt. Mit jeder Iteration (Generation) konvergiert die Population bei einem multikriteriellen Optimierungsproblem in Richtung der gesuchten Pareto-Front. Die Konvergenz hängt dabei neben der gewählten Populationsgröße vor allem von den drei genannten Operatoren ab, welche im Folgenden erläutert werden.

### Selektion

Der Selektionsoperator sichert das Überleben der besten Individuen (survival of the fittest) und reduziert dabei gleichzeitig die Diversität der Population. Überdurchschnittlich gute Lösungen werden dupliziert, während schlechte Individuen aus der Population eliminiert werden. Die Populationsgröße bleibt dabei konstant. Je höher die Fitness



eines Individuums, desto größer ist die Chance ausgewählt zu werden. Die Konvergenzgeschwindigkeit des Algorithmus hängt entscheidend vom Selektionsdruck ab. Dieser ist ein Maß dafür, wie stark Individuen mit höherer Fitness bevorzugt werden. Ein hoher Selektionsdruck hat in der Regel eine schnellere Konvergenz zur Folge. Allerdings wird die Diversität der Lösungen dadurch reduziert. Ferner steigt die Gefahr, dass die Population zu einer suboptimalen Lösung konvergiert. Ein zu niedriger Selektionsdruck hingegen führt zu einer niedrigen Konvergenzrate und die Evolution verläuft nur sehr langsam.

Es existieren verschiedene Selektionsverfahren wie z.B. Roulette-Selektion, Ranking-Selektion, Abschneidungsselektion<sup>17</sup> oder Turnierselektion<sup>18</sup>. Nach [79] weist die Turnierselektion im Vergleich zu den anderen Selektionsverfahren ein besseres oder zumindest gleichwertiges Konvergenzverhalten bei gleichzeitig niedriger Rechenkomplexität auf. Ebenfalls können damit Skalierungsprobleme, die z.B. bei der Roulette-Selektion auftreten können, vermieden werden [43].

Bei der Turnierselektion treten mindestens zwei zufällig aus der Gesamtpopulation ausgewählte Individuen gegeneinander an, wodurch der Selektionsdruck gefördert wird. Die Lösung mit der höheren Fitness gewinnt und wird in den Genpool zur Nachkommensbildung aufgenommen. Das Verfahren wird solange wiederholt, bis der Paarungspool vollständig gefüllt ist.

### Rekombination

Bei der Rekombination werden durch Crossover neue Lösungen erzeugt. Dabei werden aus dem Paarungspool zufällig zwei Individuen ausgesucht und deren Chromosomen stückweise ausgetauscht, so dass zwei neue Lösungen entstehen. Beim Single-Point-Crossover wird zunächst zufällig eine Kreuzungsstelle entlang der Chromosomen gewählt. Anschließend werden alle Werte (Bits) nach der Kreuzungsstelle zwischen beiden Elternteilen getauscht. Der Stringaustausch kann auch mit zwei (Two-Point-Crossover) oder mehreren Kreuzungsstellen (N-Point-Crossover) erfolgen, wodurch der Variablenraum gründlicher durchsucht werden kann, die Rechenzeit allerdings ansteigt. Beim Uniform-Crossover werden die Nachkommen durch Zufallsauswahl der einzelnen Bits aus den beiden Elternstrings gebildet. Die Crossover-Wahrscheinlichkeit  $p_c$  als wichtiger Einstellparameter der Rekombination gibt an, wie oft Crossover zur Nachkommensbildung angewendet wird und beeinflusst damit auch die Konvergenzgeschwindigkeit.

---

<sup>17</sup>truncation selection

<sup>18</sup>tournament selection

Der in dieser Arbeit verwendete Algorithmus arbeitet wie bereits erwähnt mit reell codierten Variablen und nutzt den Simulated Binary Crossover (SBX) als Nachbildung des Single-Point Crossovers [43] welcher in Abschnitt 4.3 näher beschrieben wird.

### Mutation

Die Mutation verändert zufällig die genetische Information der Individuen, wodurch neue Lösungen im gesamten Suchraum generiert werden können. Der Mutationsoperator erhöht die Diversität der Population und verhindert gleichzeitig die Konvergenz des Algorithmus zu lokalen Optima hin. Es wird zudem sichergestellt, dass die Wahrscheinlichkeit, einen beliebigen Punkt im Suchraum zu erreichen, immer größer als Null ist. Bei binär codierten Algorithmen kann eine Mutation z.B. durch Invertieren der Bits eines Strings mit einer bestimmten, meist geringen Wahrscheinlichkeit oder durch Austausch zweier Bits erfolgen. Reell codierte Algorithmen arbeiten auf Basis einer vorgegebenen Wahrscheinlichkeitsverteilung, z.B. gleich-, gauß- oder polynomialverteilt [43]. Einen guten Überblick über reell codierte Crossover- und Mutationsoperatoren gibt [87]. Ähnlich wie beim Crossover existiert auch für die Mutation eine Wahrscheinlichkeit  $p_m$ , die bestimmt, wie oft der Operator angewendet wird. Die Mutation sollte im Vergleich zum Crossover nicht zu oft eingesetzt werden, da der genetische Algorithmus ansonsten zu einer Zufallssuche verkommt.

### Replacement und Elitismus

Als letzter Schritt ist erneut eine Auswahl (Replacement) zu treffen, welche Individuen aus Eltern- und Filialpool in die Folgegeneration aufgenommen werden und damit überleben. Hierbei wird prinzipiell zwischen der gesamthaften (generational) und der stetigen (steady-state) Aktualisierung der Folgegeneration unterschieden. Letztere Variante integriert die neuen Individuen unmittelbar in die Population, wodurch ein anderes Individuum, z.B. das schwächste, ersetzt wird. Beim gesamthaften Update kann z.B. die Filialpopulation der Größe  $\lambda$  die Elternpopulation der Größe  $\mu$  komplett ersetzen. Eine weitere Möglichkeit ist die Auswahl der  $\mu$  besten Individuen aus der Menge der Eltern und Kinder ( $(\mu + \lambda)$ -Update) oder lediglich aus dem Filialpool ( $(\mu, \lambda)$ -Update), sofern mehr Kinder generiert werden als Eltern vorhanden sind ( $\lambda \geq \mu$ ).

Eine wichtige Eigenschaft genetischer Algorithmen ist der Elitismus, d.h. die Fähigkeit, die besten Individuen einer Elterngeneration in die Folgegeneration zu übernehmen. Diese Lösungen könnten unter Umständen verloren gehen, sofern sie bei der Selektion nicht ausgewählt bzw. beim Crossover oder der Mutation zerstört werden. Vergleiche ver-

schiedener genetischer Algorithmen zeigen, dass ein Elitismus-Operator einen positiven Einfluss auf die Lösungsgüte sowie die Berechnungsdauer hat [184, 216, 45, 155, 112]. Eine einfache Implementierung des Elitismus ist z.B. die Übernahme der besten  $\epsilon$  % einer Population in die Folgegeneration. Der restliche Anteil wird durch Anwendung der beschriebenen Operatoren auf die gesamte Population inkl. der  $\epsilon$  % Eliteindividuen generiert. Dadurch werden die besten Lösungen nicht einfach nur in die Folgegeneration übernommen, sondern haben die Möglichkeit, ihre Gene auch noch weiter zu vererben [43]. Eine weitere Umsetzung von Elitismus ist die Auswahl der besten  $N$  Individuen aus der kombinierten Population aus Eltern und Kindern der Größe  $2N$  [67].

### Abbruchbedingungen

Der vorgestellte Optimierungsprozess wird so lange durchlaufen, bis eine Abbruchbedingung erfüllt ist. Im einfachsten Fall wird eine vom Nutzer definierte maximale Generationenanzahl erreicht. Andere Abbruchkriterien berücksichtigen z.B. die *crowding distance* als Maß für die Diversität der Lösungsmenge oder die Diskretisierungsschrittweite der Entscheidungsparameter (Abschnitt 4.3.2).

### 2.4.4 Unterschiede und Eignung der Verfahren

Das No-Free-Lunch-Theorem beschreibt den Zusammenhang zwischen Effizienz und Robustheit von Such- und Optimierungsalgorithmen. Demnach liefert ein problem-spezifischer Algorithmus für eine bestimmte Problemklasse immer bessere Ergebnisse als eine generalisierte Methode (vgl. Abbildung 2.7). Umgekehrt lässt sich immer ein Problem konstruieren, bei dem der spezialisierte Algorithmus schlechter abschneidet [202]. Es existiert also kein Algorithmus, der über alle möglichen Problemstellungen hinweg robust und effizient arbeitet. Enumerative Verfahren sind zwar auf alle Probleme anwendbar, liefern aber durchweg eine schlechte Performance. Ohne problemspezifisches Wissen kann ein Suchalgorithmus die Performance einer enumerativen Methode nicht übertreffen [145]. Die Performance von Algorithmen, welche auf eine breite Klasse von mathematischen Problemen angewendet werden, ist im Mittel gleich [206]. Eine abschließende Bewertung der hier vorgestellten Algorithmen für die vorliegende Aufgabe der Optimierung der Betriebsstrategie von Hybridfahrzeugen kann daher nicht erfolgen, da sich der Zielfunktionsraum in Abhängigkeit von den gewählten Optimierungsparametern und Zielgrößen ändert.

Das zu betrachtende Optimierungsproblem kann wie viele ingenieurtechnische Aufgabenstellungen als Black-Box-Problem angesehen werden. Die Zielgrößen (multikriteriell)




Abbildung 2.7: Beispielhafte Visualisierung des No-Free-Lunch Theorems nach [78, 202]

können daher nicht geschlossen als Funktion der Entscheidungsvariablen dargestellt werden. Zur Bestimmung der einzelnen Zielfunktionswerte sind u.U. zeitaufwändige Simulationen notwendig. Die große Menge an schaltenden Elementen und Nichtlinearitäten in der Betriebsstrategie führt zu einem nicht stetigen und nichtlinearen Verhalten. Ferner wird von einem multimodalen Suchraum sowie diskreten Entscheidungsvariablen ausgegangen.

Da eine analytische Bestimmung der Gradienten der Zielfunktionen im vorliegenden Problem nicht möglich ist, können gradientenbasierte Verfahren nicht verwendet werden. Durch die multimodalen Zielfunktionsräume besteht bei vielen Verfahren die Gefahr in lokalen Optima hängen zu bleiben. Das gefundene Optimum hängt zudem entscheidend vom gewählten Startpunkt ab. Enumerative Verfahren können zwar angewendet werden, führen aber wenn überhaupt nur auf Kosten sehr langer Rechenzeiten und damit schlechter Effizienz zu einem Ergebnis. Mit den in Abschnitt 2.4.2 vorgestellten Lösungsmethoden für multikriterielle Probleme kann im Idealfall immer nur eine Pareto-optimale Lösung pro Simulationsdurchlauf gefunden werden, da das ursprüngliche Problem auf ein einkriterielles Problem zurückgeführt wird. Für einige der Methoden existieren Theoreme, nachdem jede Lösung des abgewandelten einkriteriellen Problems auch eine Pareto-optimale Lösung darstellt. Die gefundene Lösung hängt dabei von

den gewählten Parametern (Gewichte, Schranken, Zielwerte) der jeweiligen Methode ab. Zum Auffinden verschiedener Pareto-optimaler Lösungen ist eine Variation der Parameter erforderlich, so dass für  $N$  Pareto-optimale Lösungen mindestens  $N$  einkriterielle Probleme generiert und gelöst werden müssen. Um möglichst viele verschiedene Pareto-optimale Lösungen zu erhalten, benötigen alle genannten Methoden problemspezifisches Wissen. Eine gleichmäßig verteilte Wahl der Gewichtsvektoren bei der Methode der gewichteten Summe für die einzelnen einkriteriellen Probleme garantiert keineswegs homogen verteilte Lösungen auf der Pareto-Front. Unterschiedliche Gewichtsvektoren können z.B. in einen identischen Optimalpunkt im Suchraum resultieren. Bei nichtkonvexen Problemen können einige Ansätze zudem nicht alle Pareto-optimale Lösungen finden. Die Nutzenfunktionsmethode, die Methode der gewichteten Summe sowie der gewichteten Metrik können unabhängig von den gewählten Parametern keine Lösungen im nichtkonvexen Suchraum generieren [43].

Die in Abschnitt 2.4.3 vorgestellten genetischen Algorithmen unterscheiden sich im Vergleich zu den klassischen Such- und Optimierungsverfahren durch folgende Punkte [78]:

- GA arbeiten mit mehreren Lösungspunkten, der Population, gleichzeitig anstatt mit nur einer Einzellösung.
- GA nutzen probabilistische Regeln und sind daher nicht deterministisch.
- GA arbeiten mit codierten Entscheidungsvariablen und nicht den Variablenwert selbst.
- GA verwenden eine Fitnessfunktion (Zielfunktionswerte) und benötigen keine Gradienten oder spezifischen Informationen über das Optimierungsproblem.

Durch die Arbeit mit einer Menge an möglichen Lösungen reduziert sich die Gefahr lediglich lokale Optima zu finden erheblich, da der Suchraum großräumig abgedeckt wird. GA arbeiten nicht deterministisch und können auf eine breite Klasse an Problemen (nicht differenzierbare, diskontinuierliche Funktionen, diskrete Parameterräume) angewandt werden. Ebenfalls vorteilhaft ist die Eigenschaft, dass keine Informationen über das Optimierungsproblem benötigt werden, weshalb GA für Black-Box-Probleme geeignet sind. Bei vielen klassischen Verfahren ist das Auffinden einer optimalen Lösung dagegen abhängig vom gewählten Startpunkt der Optimierung. Dieser kann ohne problemspezifisches Wissen jedoch nicht gezielt gewählt werden. GA finden bei multikriteriellen Problemstellungen auch bei nicht-konvexen Pareto-Fronten die optimale Lösungsmenge.

Es besteht zudem die Möglichkeit den Optimierungsprozess zu parallelisieren. Damit können z.B. die einzelnen, mitunter zeitintensiven Simulationsaufrufe zur Auswertung der Zielfunktionswerte auf unterschiedlichen Rechnern ausgeführt werden oder mehrere Populationen laufen parallel auf unterschiedlichen Rechnern verteilt, zwischen denen ein zusätzlicher Informationsaustausch stattfindet [29].

Die Anwendungen eines GA garantiert jedoch keineswegs das Auffinden des globalen Optimums (in unserem Fall der Pareto-Front), aber ermöglicht eine gute Approximation. Des Weiteren sollen die gefundenen Lösungen möglichst gleichmäßig auf der Pareto-Front verteilt und deren Ausdehnung maximal sein. Dabei ist die Balance zwischen *exploration* (Erkundung, Breitensuche) und *exploitation* (Ausnutzung, Tiefensuche) entscheidend für den Erfolg bzw. das Konvergenzverhalten des verwendeten Algorithmus [91, 92, 79, 68, 63]. Während die Operatoren Mutation und Rekombination maßgeblich die *exploration* vorantreiben, ist der Selektionsoperator primär für die *exploitation* zuständig. Ein zu hoher Selektionsdruck kann wie bereits erwähnt die Diversität der Lösungen reduzieren und die Konvergenz zu lokalen Optima hin fördern, da zu viele Kopien der besten Individuen erzeugt werden. Umgekehrt verhält sich der Algorithmus bei niedrigem Selektionsdruck mehr wie eine Zufallssuche und die Konvergenzgeschwindigkeit leidet. Rekombination und Mutation bringen neue Genkombinationen in die Population, wodurch die Diversität der Lösungen erhöht wird [43]. Während die meisten klassischen Such- und Optimierungsverfahren ein festes Verhältnis von *exploration* und *exploitation* besitzen, können GA dieses Verhältnis über ihre Operatoren und deren Einstellparameter steuern [81].

Daneben hat die Populationsgröße ebenfalls einen großen Einfluss auf das Konvergenzverhalten. Die Initialpopulation verteilt die Individuen zufällig im Parameterraum. Mit steigender Anzahl an Zielfunktionen steigt auch der Anteil an nicht-dominierten Lösungen innerhalb der Startpopulation. Der Anteil wird wiederum geringer, je größer die Population gewählt wird [43]. Da viele Algorithmen die nicht-dominierten Lösungen ähnlich oder gleich in ihrer Fitness bewerten, ergibt sich bei einem zu großen Anteil an nicht-dominierten Lösungen ein zu niedriger Selektionsdruck. Ausgehend davon schlägt [43] einen zu definierten Maximalanteil von nicht-dominerten Lösungen in der Startpopulation vor. Daraus ergibt sich auf Basis experimenteller Untersuchungen eine Mindestpopulation in exponentieller Abhängigkeit von der Dimension des Zielraums. Weitere Faktoren für die Wahl der Populationsgröße sind die schwierig messbare Komplexität des Problems oder das Rauschen der Zielfunktionen hervorgerufen durch die Varianz der Fitnessberechnung bzw. der verwendeten Operatoren [80, 85]. Im Allgemeinen erweisen sich größere Startpopulationen als sinnvoll. Jedoch erhöht mitunter eine

zu große Anzahl an Individuen die Rechenzeit immens ohne die Konvergenz bzw. die Ergebnisgüte signifikant zu steigern.

Vergleiche von multikriteriellen evolutionären Algorithmen hinsichtlich der Performance gestalten sich schwierig. In der Regel werden dafür Testprobleme herangezogen bei denen die Pareto-Front bekannt ist. Vergleichsmaße sind dann z.B. der Abstand der gefundenen optimalen Zielfunktionswerte zur eigentlichen Pareto-Front oder auch die möglichst homogene Verteilung und maximale Ausdehnung der Lösungen auf eben dieser. Hierfür existieren verschiedenste Vergleichsmaße [218, 84, 194]. Neben den Zahlenmaßen ist die grafische Aufbereitung verschiedener Lösungsfronten eine weitere einfachere Vergleichsmöglichkeit. In [216] werden verschiedene EA anhand von sechs Testfunktionen verglichen. Dabei zeigt sich, dass der Strength Pareto Evolutionary Algorithm (SPEA, [217]) in über 80 % der Fälle die besten Ergebnisse erzielt. Dies ist unter anderem auf den im SPEA implementierten Elitismus zurückzuführen, was die Wichtigkeit einer Elitismus-Strategie unterstreicht. Unter den Algorithmen ohne Elitismus weist der NSGA<sup>19</sup> [181] die beste Performance auf. Dagegen schneidet derselbe Algorithmus in einer anderen Studie [192] am schlechtesten ab. Ein Vergleich der Studien untereinander ist jedoch kaum möglich, da sowohl unterschiedliche Testprobleme als auch Einstellparameter benutzt wurden. Daneben existieren zahlreiche weitere Vergleiche von EA in der Literatur [112, 45, 184]. Eine problemunabhängige Bewertung hinsichtlich definierter Kriterien wie z.B. Konvergenzgeschwindigkeit, Rechenzeit oder Lösungsgüte ist nicht möglich, da das jeweilige Verhalten stark vom jeweiligen Testproblem abhängt. Der stochastische Charakter der Algorithmen erschwert dies zusätzlich. Ein weiterer Einfluss sind die teilweise algorithmusspezifischen Einstellparameter. Einen guten Überblick über multikriterielle GA mit ihren charakteristischen Eigenschaften sowie wesentlichen Vor- und Nachteilen gibt z.B. [114].

Weit verbreitet sind ebenfalls schwarmbasierte Optimierungsverfahren wie z.B. Particle Swarm Optimization (PSO) [103]. Die PSO orientiert sich dabei wie GA an der Natur indem das Verhalten von Tierschwärmen abgebildet wird. Neben der individuellen (lokalen) Suche orientieren sich die einzelnen Lösungen (Partikel) auch an den anderen Schwarmmitgliedern (globale Suche). Der Informationsaustausch erfolgt über einfache Aggregation der Einzellösungen. Die PSO arbeitet wie GA populationsbasiert, jedoch ohne neue Individuen im Verlauf der Optimierung zu erzeugen bzw. zu verwerfen. Vielmehr ändern die vorhandenen Individuen mit jeder Generation ihre Position abhängig von der Lage des persönlichen Optimums (kognitiver Anteil) und der Lage des Bestpunktes

---

<sup>19</sup>Non-Dominated Sorting Genetic Algorithm

aller Schwarmmitglieder (sozialer Anteil) [62, 150, 65]. Vergleiche von PSO und GA zeigen bei einer Vielzahl an einkriteriellen Problemen ähnlich gute Ergebnisse, wenngleich PSO-Algorithmen sehr oft einen Effizienzvorsprung (schnelle Konvergenz, wenige Funktionsauswertungen) aufweisen [65, 86]. Wie bereits erwähnt, ist die Bewertung der Algorithmen jedoch stark abhängig vom Testproblem und den Algorithmusparametern. Weiterhin ist zu beachten, dass bei einer multikriteriellen Anwendung der ursprüngliche PSO Algorithmus angepasst werden muss, um der Forderung nach einer möglichst homogenen und breiten Verteilung der Lösungen auf der approximierten Pareto-Front nachzukommen [150]. Nach [38] sind die Hauptnachteile von multikriteriellen PSO die schwierige Steuerung der Diversität der Lösungen und die gleichzeitig geringen Erfahrungen auf diesem Gebiet.

Der im Rahmen dieser Arbeit verwendete genetische Algorithmus wird in Abschnitt 4.3.1 vorgestellt. Da die Entwicklung und Anwendung einer Applikationsmethode für die Betriebsstrategie von Hybridelektrofahrzeugen im Vordergrund der Arbeit stand, wurde auf einen zeitaufwändigen Vergleich verschiedener Algorithmen anhand konkreter Applikationsaufgaben verzichtet. Die Auswahl orientierte sich letztendlich an der Verbreitung des Algorithmus in der Literatur und der Ingenieurpraxis.



# Kapitel 3

## Betrachteter Antriebsstrang

Die in dieser Arbeit vorgestellte Applikationsmethodik wurde am Antriebsstrang des BMW ActiveHybrid 5 [144] entwickelt und getestet. Im Folgenden wird sowohl der konkrete Fahrzeugaufbau als auch die Umsetzung des Konzeptes am Antriebsstrangprüfstand vorgestellt. Letzterer ist ein wichtiges Element zur Verifikation von Parametersätzen am realen Antriebsstrang. Weiterhin werden in diesem Abschnitt die wichtigsten Hybridfunktionen sowie deren Umsetzung auf dem Hybridsteuergerät erläutert. Neben der Lastpunktverschiebung hat die elektrische Fahrentscheidung den größten Einfluss auf den Kraftstoffverbrauch und das Hybriderlebnis. Die beiden Funktionen sind zudem Basis für die späteren Optimierungsläufe.

### 3.1 Gesamtfahrzeug

Das betrachtete Fahrzeugkonzept ist ein Full-Hybrid und verwendet eine parallele Antriebstopologie (vgl. Abschnitt 2.1). Abbildung 3.1 veranschaulicht die Anordnung der wichtigsten Komponenten. Im Vergleich zum Basisfahrzeug führen E-Maschine, Leistungselektronik (PWR<sup>1</sup> und DC/DC-Wandler<sup>2</sup>) und Hochvoltbatterie zu einer Gewichtsmehrung, welche dank der zusätzlichen elektrischen Antriebsleistung keine negativen Auswirkungen auf das Fahr- bzw. Beschleunigungsverhalten hat. Um die Funktionen von riemengetriebenen Nebenaggregaten wie Klimakompressor oder Lenkhilfepumpe auch im elektrischen Betrieb bereitstellen zu können, werden elektrisch gespeiste Alternativen eingesetzt. Der elektrische Kältemittelverdichter (EKMV) hat eine maximale elektrische Leistungsaufnahme von 5 kW und kann unabhängig vom Verbrennungsmotor betrieben werden. Der EKMV arbeitet auf dem Hochvoltspannungsniveau und beeinflusst als einer der größten Energieverbraucher im Fahrzeug

---

<sup>1</sup>Pulswechselrichter

<sup>2</sup>Direct Current/Direct Current Converter = Gleichspannungswandler

### 3 Betrachteter Antriebsstrang

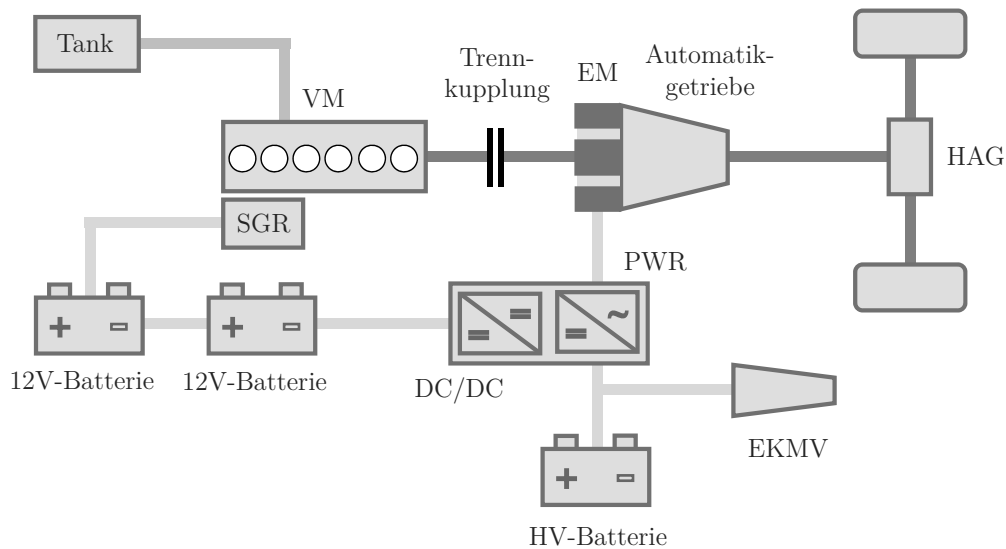


Abbildung 3.1: Antriebsstrangtopologie des betrachteten Hybridelektrofahrzeugs

maßgeblich das Hybriderlebnis sowie den Kraftstoffverbrauch. Zur Aufrechterhaltung der Bremskraftunterstützung während des elektrischen Fahrbetriebs kommt eine elektrische Unterdruckpumpe zum Einsatz, welche wie die elektrische Lenkhilfpumpe vom 12 V-Bordnetz versorgt wird. Zum Starten des Verbrennungsmotors während des elektrischen Fahrbetriebs wird ein Startergenerator im Riementrieb (SGR) verwendet. Dieser hat eine maximale Leistungsaufnahme von 2.7 kW und benötigt eine zusätzliche, vom 12 V-Bordnetz über ein Relais galvanisch trennbare 12 V-Batterie. Im Fahrzeug ist zusätzlich ein Aktivkohlefilter (AKF) verbaut, welcher die Kohlenwasserstoffemissionen (HC-Emissionen) des Fahrzeugkraftstofftanks aufnimmt. Zur Regeneration muss ein voll beladener AKF mit Umgebungsluft gespült werden, da dieser anderenfalls durchbrechen kann. Die Spülgase werden schließlich als ein HC-Luft-Gemisch bei laufendem Verbrennungsmotor der Verbrennung zugeführt.

In den folgenden Abschnitten werden die aus Sicht der energetischen Betriebsstrategie wichtigsten Fahrzeugkomponenten sowie deren Kennwerte und Eigenschaften vorgestellt.

#### 3.1.1 Verbrennungsmotor

Im vorliegenden Konzept kommt ein 3.0-Liter-Reihensechszylinder-Benzinmotor mit einem Turbolader, angetrieben von zwei Abgaskanälen (Twin-Scroll Technologie) und vollvariabler Ventilsteuerung (Valvetronic) sowie Direkteinspritzung zum Einsatz [109]. Das maximale Drehmoment beträgt 400 Nm bei 1200–5000 U/min, die maximale Leistung

von 225 kW(300 PS) wird bei 5800 U/min erreicht. Der folgende Abschnitt erläutert die für die Arbeit relevanten Eigenschaften des Verbrennungsmotors näher. Tiefere Einblicke in die Funktionsweise von Ottomotoren gibt z.B. [64, 191].

Der Verbrennungsmotor wirkt als Wärmekraftmaschine und wandelt die chemische Energie des Kraftstoffs in mechanische Energie um. Der absolute Wirkungsgrad eines Verbrennungsmotors ist definiert als Quotient aus effektiv verfügbarer mechanischer Leistung  $P_{mech,eff}$  an der Kurbelwelle und zugeführter chemischer Leistung  $P_{chem}$  (Gleichung 3.1).

$$\eta_{VM,abs} = \frac{P_{mech,eff}}{P_{chem}} \quad (3.1)$$

Abbildung 3.2 zeigt das absolute Wirkungsgradkennfeld des betrachteten Sechszylinder-Benzinmotors. Der beste Wirkungsgrad zeigt sich im mittleren Drehzahlbereich nahe der




Abbildung 3.2: Wirkungsgradkennfeld des Verbrennungsmotors

Volllast während im Teillastbereich deutlich niedrigere Wirkungsgrade erreicht werden.

Trägt man die chemische Leistung über die effektive mechanische Leistung auf, erhält man die Darstellung als Willans-Linien [191, 141]. Diese setzen Ein- und Ausgangsgrößen des Motors bei konstanter Drehzahl ins Verhältnis zueinander. In Abbildung

### 3 Betrachteter Antriebsstrang

3.3 sind die Willans-Linien des betrachteten Verbrennungsmotors für verschiedene Drehzahlen dargestellt. Als Eingangsgröße dient der Kraftstoffmassenstrom, welcher mit dem Heizwert in eine chemische Leistung überführt werden kann. Als Ausgangsgröße wird die effektive mechanische Leistung verwendet.




Abbildung 3.3: Willans-Linien des Verbrennungsmotors für verschiedene Drehzahlen

Der Schnittpunkt der Willans-Linie mit der Ordinate entspricht dem Grund- oder Leerlaufverbrauch. Je größer die Drehzahl des Verbrennungsmotors ist, desto mehr chemische Energie muss aufgewendet werden um an der Kurbelwelle eine nutzbare mechanische Leistung zu erzeugen.

Für die energetische Bewertung einer Lastpunktverschiebung ist der relative Wirkungsgrad des Verbrennungsmotors  $\eta_{VM,rel}$  (Gleichung 3.2) entscheidend [203, 196, 71, 24].

$$\eta_{VM,rel} = \frac{\Delta P_{eff,mech}}{\Delta P_{chem}} \quad (3.2)$$

Dieser setzt z.B. bei einer Lastpunktanhebung die zusätzlich benötigte chemische Energie ins Verhältnis zur zusätzlich erzeugten mechanischen Energie und ist damit ein Maß für die Effizienz der Energieerzeugung. Der relative Wirkungsgrad entspricht der Steigung der Willans-Linie und ist für niedrige Ausgangsleistungen nahezu konstant (vgl. Abbildung 3.3). Für hohe Lasten verläuft der Anstieg steiler, d.h. der relative Wirkungsgrad verschlechtert sich, was auf die Anfettung im Bereich der Vollast zurückzuführen ist [191]. Das Kraftstoffverbrauchspotenzial eines Hybridfahrzeugs ergibt sich primär aus der Möglichkeit, den Grundverbrauch des Verbrennungsmotors durch temporäre

Abschaltung einzusparen. Dies ist vor allem im Stillstand und in Verzögerungsphasen sinnvoll. Des Weiteren kann durch Rekuperation gewonnene Energie für die Versorgung des Bordnetzes bzw. den elektrischen Vortrieb genutzt werden. Durch die Lastpunktverschiebung kann der absolute Wirkungsgrad des Verbrennungsmotors verbessert werden. Der relative Wirkungsgrad ist für den betrachteten Verbrennungsmotor über einen großen Betriebspunktbereich nahezu konstant. Jedoch darf bei der Effizienzbewertung einer Lastpunktverschiebung der Wirkungsgrad des elektrischen Systems nicht außer Acht gelassen werden (Abschnitt 3.3.1).

### 3.1.2 E-Maschine und Leistungselektronik

Elektrische Maschinen können elektrische und mechanische Energie bidirektional wandeln. Im untersuchten Antriebsstrang wird eine permanenterrregte Synchronmaschine (PSM) mit einer Maximalleistung von 40 kW und einem Maximaldrehmoment von

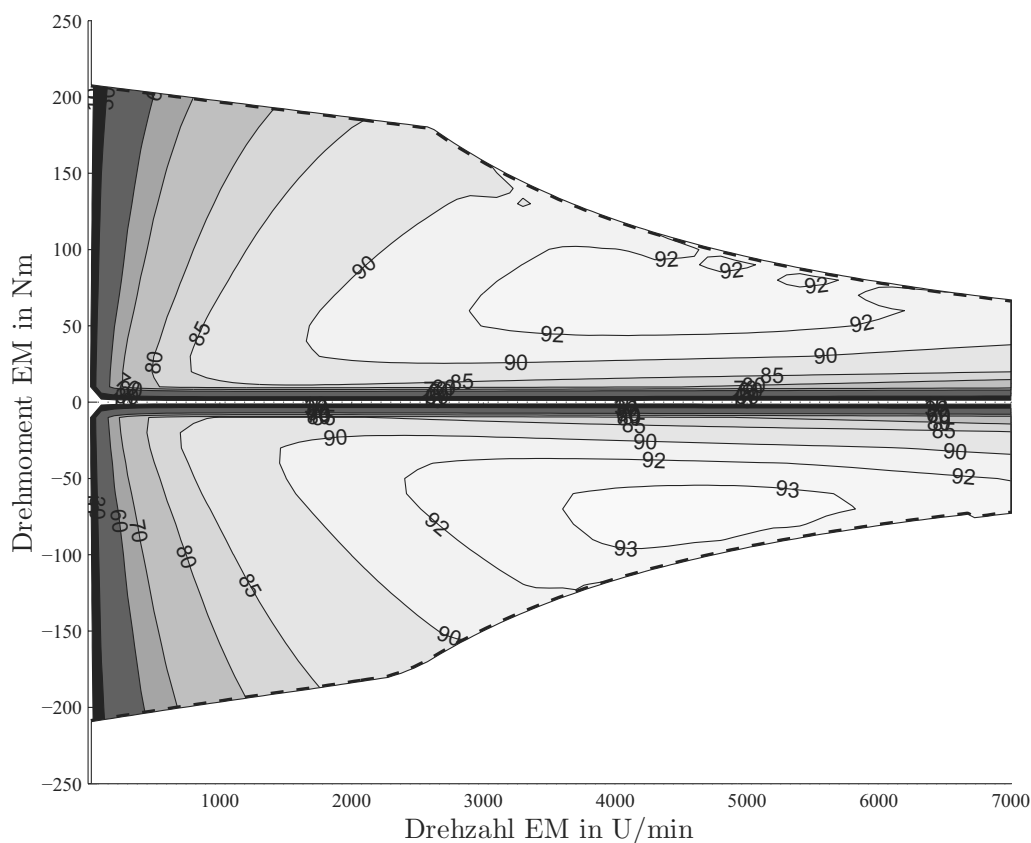


Abbildung 3.4: Wirkungsgradkennfeld der E-Maschine inkl. Leistungselektronik

210 Nm eingesetzt. Die Leistungselektronik umfasst neben dem Pulswechselrichter auch den integrierten DC/DC-Wandler. Letzterer versorgt das 12 V-Bordnetz mit maximal

### 3 Betrachteter Antriebsstrang

2.8 kW Leistung. Der Pulswechselrichter wandelt die Gleichspannung der Hochvoltbatterie in eine dreiphasige Wechselspannung veränderlicher Phasenlage, Frequenz und Amplitude zur Regelung von Drehzahl und Drehmoment der E-Maschine. Umgekehrt wird die Wechselspannung im Generatorbetrieb gleichgerichtet.

In Abbildung 3.4 ist das absolute Wirkungsgradkennfeld der elektrischen Antriebseinheit bestehend aus E-Maschine und Pulswechselrichter dargestellt. Hierbei ist zwischen dem motorischen Betrieb, d.h. Umwandlung von elektrischer in mechanische Energie, und dem generatorischen Betrieb, d.h. Umwandlung von mechanischer in elektrischer Energie, zu unterscheiden (Gleichung 3.3 und 3.4).

$$\eta_{EM,abs,mot} = \frac{P_{EM,mech}}{P_{EM,el}} \quad (3.3)$$

$$\eta_{EM,abs,gen} = \frac{P_{EM,el}}{P_{EM,mech}} \quad (3.4)$$

Die absoluten Wirkungsgrade sind deutlich höher als beim Verbrennungsmotor (vgl. Abbildung 3.2). Jedoch ist die Leistungs- und Energiedichte der verfügbaren elektrischen Energiespeicher um ein Vielfaches geringer (vgl. Abschnitt 3.1.4). Abbildung 3.5 zeigt die Willans-Linien der elektrischen Antriebseinheit für verschiedene Drehzahlen.

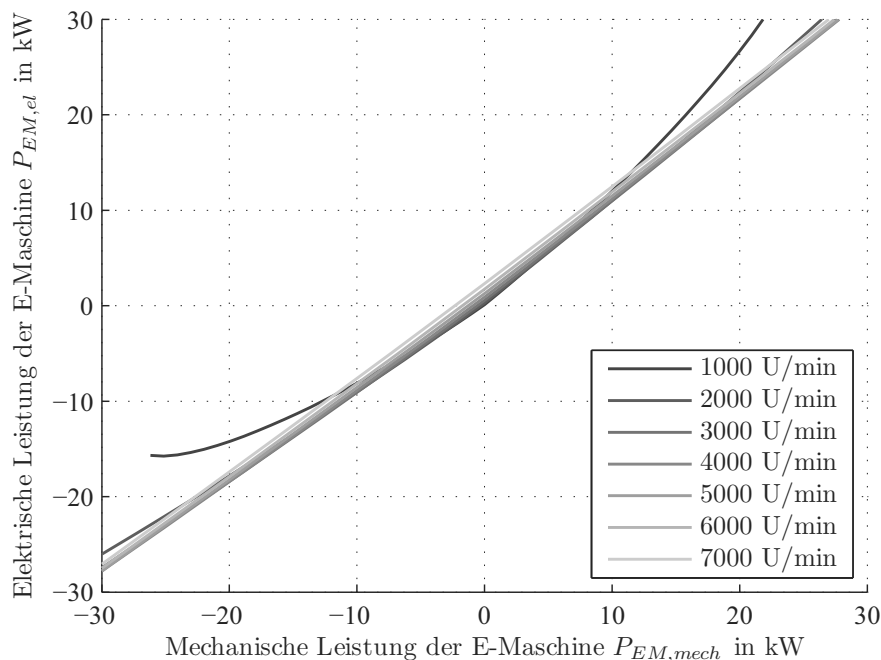


Abbildung 3.5: Willans-Linien der E-Maschine inkl. Leistungselektronik für verschiedene Drehzahlen

Charakteristisch für E-Maschinen ist das bereits im Stillstand verfügbare maximale Drehmoment (Abbildung 3.4). Aufgrund des hohen Wirkungsgrades verbunden mit einer hohen Leistungsdichte kommen in elektrifizierten Antriebssträngen fast ausschließlich PSM zum Einsatz [90].

Im Vergleich zum Verbrennungsmotor entstehen deutlich geringere Grundverluste. Im unteren Drehzahlbereich ist eine starke Abhängigkeit des relativen Wirkungsgrades (Gleichung 3.5) vom Drehmoment zu erkennen.

$$\eta_{EM,rel,mot} = \frac{\Delta P_{EM,mech}}{\Delta P_{EM,el}} \quad (3.5)$$

Die E-Maschine ist beim betrachteten Parallelhybridkonzept in das Getriebe integriert. Sowohl E-Maschine als auch Leistungselektronik werden in je einem separaten Kühlkreislauf flüssigkeitsgekühlt.

### 3.1.3 Getriebe

Das Getriebe als Wandler für Drehmoment und Drehzahl verbindet den Verbrennungsmotor und die E-Maschine mit der Abtriebsseite. Das im vorgestellten Fahrzeug verbaute Hybridgetriebe basiert auf einem konventionellen Achtgang-Automatikgetriebe [197]. An Stelle des Drehmomentenwandlers ist die zuvor beschriebene E-Maschine, ein Zweimassenschwungrad als Torsionsdämpfer sowie eine nasslaufende Trennkupplung ( $K0$ ) in das Getriebegehäuse integriert. Letztere ermöglicht das Abkoppeln des Verbren-




Abbildung 3.6: Getriebetopologie 8P70H

nungsmotors vom Antriebsstrang und damit einen rein elektrischen Fahrbetrieb. Der Torsionsdämpfer bildet das Koppellement zwischen Verbrennungsmotor und Getriebe. Weiterhin existiert eine zusätzliche elektrische Ölpumpe zur Aufrechterhaltung des

### 3 Betrachteter Antriebsstrang

Öldrucks im Getriebe bei nicht laufendem Verbrennungsmotor. Abbildung 3.6 zeigt die Getriebetopologie [144].

Zur Darstellung der neun Übersetzungsverhältnisse bzw. Gangstufen stehen vier Planetenradsätze zur Verfügung. Als Schaltelemente kommen zwei Bremsen (A,B) und drei Kupplungen (C,D,E) zum Einsatz, wobei pro Gang jeweils zwei Elemente geöffnet sind (Tabelle 3.1). Die Bremse B dient dabei zum Anfahren aus dem Stillstand (integriertes

Gang	Übersetzung	Bremse		Kupplung		
		A	B	C	D	E
R	-3.317	x	x		x	
1	4.714	x	x	x		
2	3.143	x	x			x
3	2.106		x	x		x
4	1.667		x		x	x
5	1.285		x	x	x	
6	1.000			x	x	x
7	0.839	x		x	x	
8	0.667	x			x	x

Tabelle 3.1: Schaltschema 8P70H-Getriebe

Anfahrelement). Der sechste Gang ist als Direktgang ausgelegt. Die Gesamtspreizung beträgt 7.071. Alle Einfach- bzw. Zweifachschaltungen sind als einfache Direktschaltungen darstellbar [197]. Das Gesamtgewicht des Getriebes inkl. E-Maschine und Getriebeöl beläuft sich auf ca. 106 kg. Das maximale Eingangsdrehmoment beträgt 700 Nm, davon maximal 650 Nm vom Verbrennungsmotor [144].

#### 3.1.4 Hochvolt-speicher

Zur Zwischenspeicherung der elektrischen Energie kommen in elektrifizierten Antriebssträngen neben elektrostatischen Speichern (z.B. Doppelschichtkondensatoren) vor allem elektrochemische Speicher, z.B. Nickel-Metallhydrid (NiMH), Nickel-Cadmium (NiCD), Lithium-Polymer, Lithium-Ionen (Li-Ion) oder Blei-Säure (Pb), zum Einsatz [90]. Neben der Lebensdauer und den Herstellungskosten sind die maximale Leistung und Energie bezogen auf das Speichergewicht entscheidende Auswahlkriterien. Das Ragone-Diagramm in Abbildung 3.7 zeigt beispielhaft Energie- und Leistungsdichte verschiedener Energiespeicher bezogen auf ihr Gewicht. Um die fahrzeugspezifischen Anforderungen bezüglich elektrische Reichweite und Fahrleistung zu erfüllen wird eine hohe Energiedichte bei gleichzeitig hoher Leistungsdichte benötigt. Wie Abbildung 3.7



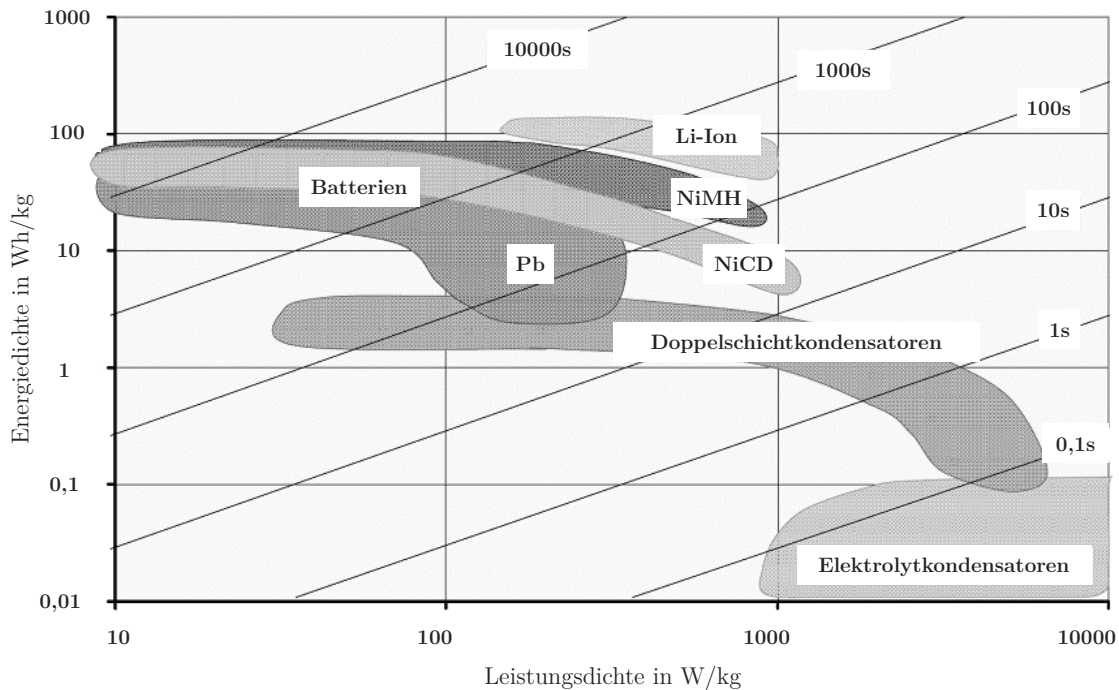


Abbildung 3.7: Klassifikation verschiedener Speichertechnologien im Ragone-Diagramm [198]

zeigt sind Lithium-Ionen-Batterien und Speicher basierend auf der Nickeltechnologie am ehesten für hybridspezifische Anwendungen geeignet. Lithium-Ionen-Zellen besitzen zudem eine hohe Einzelzellspannung, wodurch weniger Zellen im Verbund für ein gefordertes Spannungsniveau benötigt werden. Sie weisen ferner eine geringe Selbstentladung auf und besitzen ein gutes Langzeitverhalten (zyklische und kalendarische Lebensdauer)<sup>3</sup>. Nachteilig ist die hohe Empfindlichkeit gegenüber thermischer und elektrischer Überlastung (Überladung, Tiefentladung), die relativ hohen Kosten sowie aufwendige Sicherheitskonzepte [135, 90, 105].

Im betrachteten Konzept wird eine Lithium-Ionen-Batterie mit einem Energieinhalt von 1.4 kWh und einer maximalen Leistung von 43 kW eingesetzt. Die Hochvoltbatterie setzt sich aus 96 in Reihe geschalteten Einzelzellen zusammen und hat eine Nennspannung von 317 V. Aufgrund der hohen thermischen Empfindlichkeit der Lithium-Ionen-Technologie ist die Einhaltung der Betriebstemperaturgrenzen entscheidend für die Batterielebensdauer [23]. Die Batterie verfügt daher über eine Direktkältemittelkühlung, welche mit dem EKMV gekoppelt ist. Ein aktives Batteriemanagement steuert neben

<sup>3</sup>Während die kalendarische Alterung primär von der Temperatur abhängt, wird die Zyklenlebensdauer hauptsächlich von den Lade- und Entladeprofilen beeinflusst.

### 3 Betrachteter Antriebsstrang

der Kühlung auch Sicherheits- und Diagnosefunktionen (z.B. Isolationswächter, Überwachung der Einzelzellspannungen) und beinhaltet zudem die SOC-Berechnung sowie Leistungsprognose. Weitere entscheidende Einflussgrößen auf die Batterie-Lebensdauer sind der Energiedurchsatz sowie die Entladetiefe [105]. Das Ende der Lebensdauer wird erreicht, wenn z.B. die Kapazität oder die Leistung der Hochvoltbatterie einen bestimmten Prozentwert des Ausgangswertes unterschreitet.

Der SOC der Hochvoltbatterie ergibt sich aus dem Verhältnis vom aktuellen Energieinhalt in Form der Ladungsmenge  $Q_{akt}$  in Ah zur Nennkapazität  $Q_{ges}$ :

$$SOC = \frac{Q_{akt}}{Q_{ges}} \quad (3.6)$$

Die Nennkapazität wird üblicherweise in Ah angegeben, welche damit der Gesamtladungsmenge entspricht.

Da die Kapazität nicht direkt gemessen werden kann, wird sie indirekt aus Strom und Spannung ermittelt. Die Ruhespannung<sup>4</sup> einer Lithium-Ionen-Zelle ist abhängig vom SOC. Bei bekannter Spannung können im stromlosen Betrieb somit Rückschlüsse auf den aktuellen Ladezustand gezogen werden. Dieser kann in der Regel im nicht stromlosen Fahrbetrieb in Verbindung mit der Integration des Batteriestromes  $I_{bat}$  zur Ermittlung des aktuellen Ladezustands herangezogen werden (Gleichung 3.7).

$$SOC(t) = SOC(t_0) + \frac{1}{Q_{ges}} \int_{t_0}^t I_{bat}(t) dt \quad (3.7)$$

Ausgehend von den Anforderungen hinsichtlich Lebensdauer sowie Startfähigkeit nach langen Standzeiten (Selbstentladung) ergibt sich ein definiertes SOC-Arbeitsfenster für die Betriebsstrategie mit der oberen Grenze  $SOC_{max}$  und der unteren Grenze  $SOC_{min}$ . Der  $SOC$  wird für die interne Berechnung der Hybridfunktionen auf diese beiden Grenzwerte zu  $SOC_{rel}$  normiert, so dass die Betriebsstrategie unabhängig von Änderungen des Arbeitsfensters ist (Gleichung 3.7).

$$SOC_{rel} = \frac{SOC - SOC_{min}}{SOC_{max} - SOC_{min}} \quad (3.8)$$

Die technischen Daten des Fahrzeugs sind in Tabelle 3.2 abschließend zusammengefasst. Durch Leistungs- und Drehmomentenaddition steht eine maximale Systemleistung von 250 kW sowie ein maximales Drehmoment von 450 Nm zur Verfügung. Die Beschleunigungszeit von 0 auf 100 km/h beträgt 5.9 s und entspricht damit trotz Gewichtsmehrung

---

<sup>4</sup>Sich im stromlosen Betrieb einstellende Klemmenspannung nach Abschluss aller Ausgleichsvorgänge.

	Merkmal	Wert [Einheit]
Verbrennungsmotor	Nennleistung	225 kW
	Maximalmoment	400 Nm
E-Maschine	Nennleistung	29 kW
	Maximalmoment	210 Nm
Fahrzeug	Übersetzung Hinterachsgetriebe	2.93
	Masse	1925 Kg
	Stirnfläche	2.35 m <sup>2</sup>
	Widerstandsbeiwert	0.28
Getriebe	Typ	Automatik
	Gänge (ohne Rückwärtsgang)	8
HV-Speicher	Typ	Li-Ion
	Energieinhalt gesamt/nutzbar	1392/626 Wh

Tabelle 3.2: Technische Daten des betrachteten Fahrzeugs

dem Wert des Basisfahrzeugs [144].

## 3.2 Antriebsprüfstand

Der im vorhergehenden Abschnitt vorgestellte Antriebsstrang wurde für Entwicklungs- und Inbetriebnahmetests als Prüfstands Aufbau realisiert (Abbildung 3.8). Der Prüfling umfasst Verbrennungsmotor, Getriebe und E-Maschine sowie die korrespondierenden Steuergeräte (ECU)<sup>5</sup>. Die Hochvoltbatterie wird am Prüfstand durch eine Laborstromversorgung<sup>6</sup> ersetzt, welche als Stromquelle und Stromsenke dient (Zwei-Quadranten-Betrieb). Der Senkenbetrieb erfolgt ohne Umschaltung abhängig vom Spannungsniveau des Hybridsystems, sobald die angelegte Klemmenspannung die vorgegebene Sollspannung<sup>7</sup> übersteigt. Strom und Spannung werden über frei einstellbare Strom-Spannung-Kennlinien geregelt, welche lediglich durch die Maximalleistung begrenzt sind. Über parametrierbare Innenwiderstände kann die Kennliniencharakteristik vorgegeben werden. Der Prüfstands Aufbau erlaubt alternativ auch die Anbindung eines realen Hochvoltspeichers mit dazugehörigem Steuergerät.

Eine Lastmaschine (Prüfstands-E-Maschine) ist über eine starre Verbindungswelle mit dem Getriebe verbunden und ermöglicht das Schleppen oder Bremsen des

<sup>5</sup>Electronic Control Unit

<sup>6</sup>Bidirektionale - DC -Versorgung Typ RTS-DC-3865 [82]

<sup>7</sup>Die vorgegebene Sollspannung entspricht der Ruhespannung der abzubildenden Hochvoltbatterie.

### 3 Betrachteter Antriebsstrang

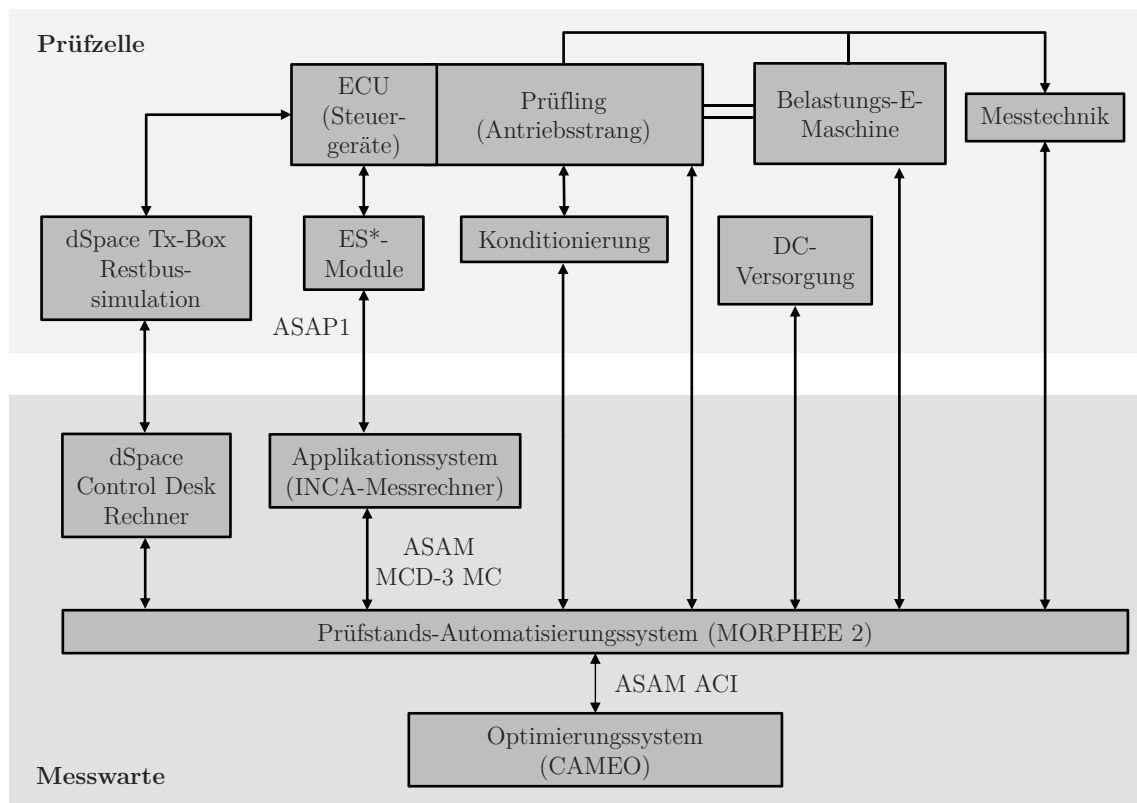


Abbildung 3.8: Aufbau von Prüfzelle und Bedienwarte des Antriebsprüfstands

Antriebsstrangs. Die Auslegungswerte der Drehstrom-Asynchronmaschine als Belastungsmaschine sowie die Leistungsdaten der bidirektionalen DC-Versorgung sind in Tabelle 3.3 zusammengefasst.

Die Konditionierung des Prüflings umfasst die Kühlung von Getriebe, E-Maschine und Verbrennungsmotor sowie die Kraftstoff- und Luftversorgung. Des Weiteren ist am Prüfling Druck-, Temperatur- und Abgasmesstechnik verbaut. Der Kraftstoff wird kontinuierlich durch eine *AVL FuelExact* Messanlage gemessen [8].

Neben den genannten Komponenten beinhaltet die Prüfzelle mehrere Steuergeräte- und Schnittstellenmodule (ES590, ES910.3, ES511, ES1000) zur Kalibrierung, Diagnose und Flashprogrammierung der Steuergeräte. Als Mess- und Applikationssystem kommt INCA (Integrated Calibration and Acquisition System) von ETAS [69] zum Einsatz. Die Kommunikation zwischen INCA und den Steuergeräten sowie das Bus-Monitoring laufen über definierte Schnittstellen (ETK<sup>8</sup>, CAN<sup>9</sup>, LIN<sup>10</sup>, FlexRay) und Protokolle (CCP<sup>11</sup>,

<sup>8</sup>Emulator-Tast-Kopf

<sup>9</sup>Controller Area Network

<sup>10</sup>Local Interconnect Network

<sup>11</sup>CAN Calibration Protocol

	Merkmal	Wert [Einheit]
Lastmaschine	Maximalleistung	700 kW
	Maximalmoment	1400 Nm
	Maximaldrehzahl	10000 U/min
DC-Versorgung	Nennleistung	±60 kW
	Ausgangsspannung	6 . . . 600 V
	Ausgangsstrom	±400 A
	Stromanstiegszeit	< 3 ms

Tabelle 3.3: Technische Daten des Prüfstands

XCP<sup>12</sup>) mithilfe der oben genannten Module. Zur Umsetzung der Restbussimulation sowie für die Einbindung von Simulationsmodellen wurde eine Prozessorkarte (DS1005) mit entsprechenden CAN-Modul (DS4302) und digitalen I/O-Board (DS4001) von dSPACE [59] verwendet. Die Parametrierung der Simulationsmodelle und die Manipulation von Restbussignalen erfolgt über einen separaten Rechner mit der Experimentiersoftware *ControlDesk*.

Das Prüfstandsautomatisierungssystem MORPHEE 2 von D2T [40, 25] als Kernteil der Bedienwarte ermöglicht die Steuerung und Überwachung des Prüfstands in Echtzeit. Die Kommunikation mit INCA und damit auch der Zugriff auf die Steuergeräte erfolgt über die standardisierte *ASAM*<sup>13</sup> *MCD-3 MC* Schnittstelle. Über MORPHEE 2 werden die Lastmaschine sowie die Stromversorgungsanlage angesteuert. Über das Prüfstandssystem erfolgt auch die Konditionierung des Prüflings sowie die Klemmensteuerung. Es lassen sich sowohl manuelle als auch automatisierte Versuche am Prüfstand durchführen. Im manuellen Prüfstandsbetrieb übernimmt der Betriebsingenieur die Überwachung und Steuerung des Prüflings sowie den möglichen Applikationszugriff auf die Steuergeräte. Während eines automatisierten Tests werden Fahrprofil/Betriebspunkte durch einen Ablaufplan oder ein übergeordnetes Optimierungsprogramm an das Prüfstandsautomatisierungssystem vorgegeben, welches automatisiert und ggf. unbemannt den entsprechenden Versuch durchführt. Für solche Versuche wird das Applikations- und Optimierungswerkzeug CAMEO<sup>14</sup> von AVL List GmbH [7] eingesetzt. Für den Datenaustausch zwischen CAMEO und MORPHEE 2 wird der ASAM Standard ACI<sup>15</sup> verwendet.

<sup>12</sup>Universal Measurement and Calibration Protocol

<sup>13</sup>Association for Standardisation of Automation and Measuring Systems

<sup>14</sup>Computer Aided Method for Engine Optimization

<sup>15</sup>Automatic Calibration Interface

### 3 Betrachteter Antriebsstrang

Abbildung 3.9 zeigt die Umsetzung des Fahrzyklusbetriebs am Antriebsprüfstand sowie die wichtigsten Schnittstellen (vgl. [179, 177]). Die am Prüfstand nicht verbauten

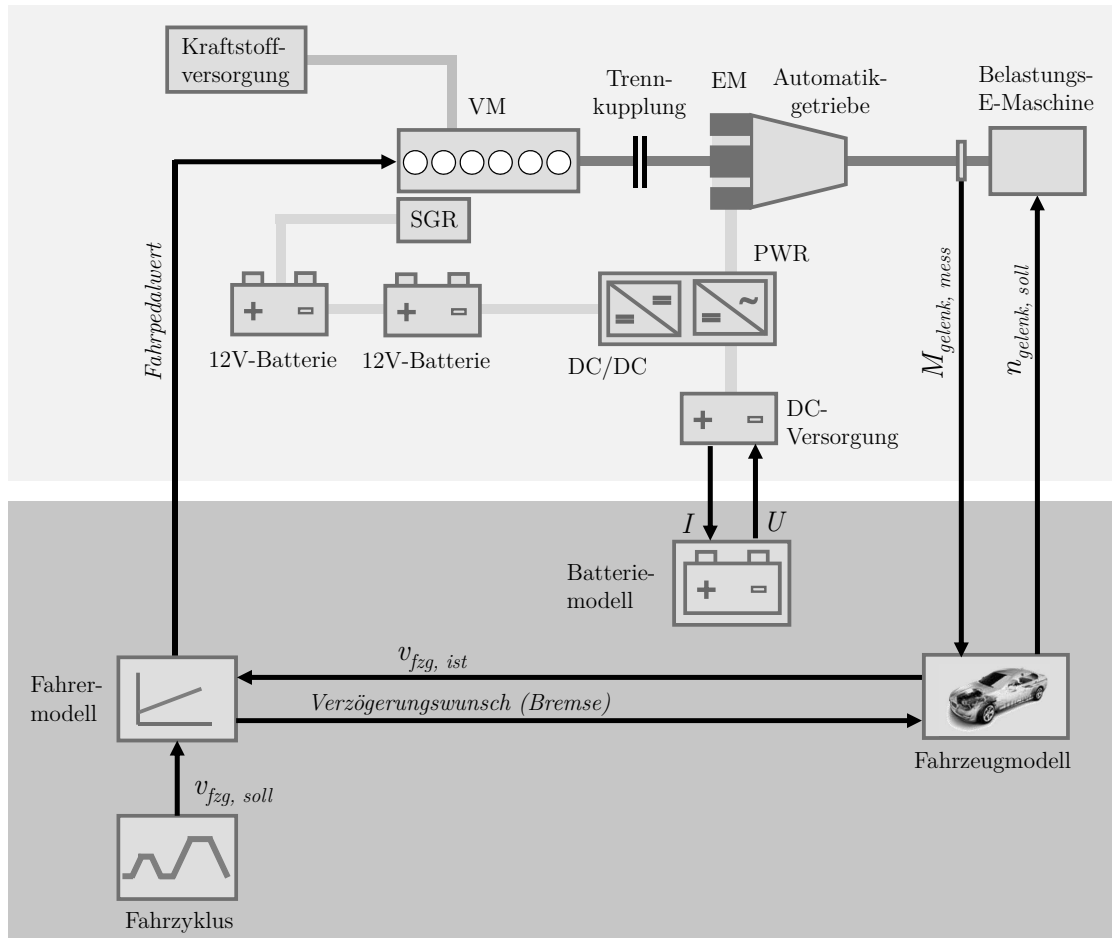


Abbildung 3.9: Umsetzung des Fahrzyklusbetriebs am Antriebsprüfstand

Fahrzeugkomponenten Hinterachsgetriebe und Hinterräder werden durch ein Fahrzeugmodell abgebildet. Dieses berechnet auf Basis des gemessenen Prüfstandsgelenkwelkenmoments  $M_{gelenk,mess}$  und unter Berücksichtigung der Fahrwiderstände eine virtuelle Fahrzeuggeschwindigkeit  $v_{fzg,ist}$ . Ein speziell für den Antriebsprüfstand konzipiertes zustandsbasiertes Fahrermodell, welchem eine  $PI$ -Reglerstruktur zu Grunde liegt, regelt  $v_{fzg,ist}$  gemäß einer Sollgeschwindigkeit  $v_{fzg,soll}$  über Ausgabe eines Fahrpedalwerts an das Motorsteuergerät bzw. eines Verzögerungswunsches auf Basis eines Radmoments. Abbildung 3.10 zeigt die verwendete Reglerstruktur für die Bildung des Fahrpedals in Form eines  $PI$ -Reglers mit einer Anti-Windup-Maßnahme zur Kompensation einer möglichen Stellgrößenbeschränkung. Die Bildung des Bremspedals wird analog dieser Struktur umgesetzt.




Abbildung 3.10: Reglerstruktur des Fahrpedalreglers am Antriebsprüfstand

Das Modell des Fahrzeugs berechnet eine Drehzahl am Getriebeausgang  $n_{gelenk, sim}$  und gibt diese als Sollwert  $n_{gelenk, soll}$  an die Lastmaschine aus. Die Drehzahlregelung übernimmt das Prüfstandsautomatisierungssystem, so dass simulierte und reale Getriebeausgangsdrehzahl identisch sind. Die aufgeführten Modelle werden auf den bereits erwähnten dSpace-System in Echtzeit gerechnet und über einen separaten *ControlDesk*-Rechner online parametrisiert. Des Weiteren ist ein Batteriemodell auf der Simulationsplattform eingebunden, welches den SOC der Hochvoltbatterie durch Integration des Klemmenstroms der Stromversorgungsanlage zur Verfügung stellt. Das Modell liefert auch den Spannungssollwert für die DC-Versorgung, wodurch diese als Stromquelle oder -senke fungiert. Im Vergleich zum realen Fahrzeug fehlende Bordnetzverbraucher können in der Energiebilanz zusätzlich berücksichtigt werden. Neben den beschriebenen Simulationsmodellen wird auch die Restbussimulation vom dSpace-System übernommen. Dabei werden CAN-Bus-Nachrichten von am Prüfstand nicht vorhandenen Steuergeräten und Sensoren nachgebildet bzw. in Echtzeit simuliert. Dazu gehören z.B. die Botschaften des nicht verbauten Steuergeräts der Hochvoltbatterie.

Die vorgestellte Konfiguration des Antriebsprüfstands erlaubt das Fahren beliebiger Geschwindigkeitsprofile (gesetzliche Zyklen, selbstdefinierte oder aufgezeichnete Geschwindigkeitsverläufe) durch einfache Sollwertvorgabe an das Fahrermodell. Am hybriden Antriebsstrang müssen lediglich die Bedingungen für „Fahrbereitschaft“ hergestellt werden. Dafür müssen zum einen alle Steuergeräte bestromt sein (Klemmensteuerung). Zum anderen ist eine Initialisierung der DC-Versorgung und des dSpace-Systems notwendig. Außerdem darf keine der zahlreichen Sicherheitsfunktionen der Prüfstandsautomatisierung zuschlagen.

## 3.3 Kernfunktionen Betriebsstrategie

### 3.3.1 Ladezustandsregelung

Die Regelung des Ladezustands der Hochvoltbatterie ist eine wesentliche Stellschraube der Betriebsstrategie und hat einen signifikanten Einfluss auf den Kraftstoffverbrauch [115, 24, 203]. Wie in Abschnitt 2.3 beschrieben, werden die Betriebsstrategiefunktionen heuristisch entwickelt. Dadurch kann insbesondere das für den Kunden geforderte reproduzierbare Systemverhalten sicher gestellt werden. Ferner können die Funktionen durch Parameteranpassungen leicht für verschiedene Fahrzeugtypen ausgelegt werden.

Die der Arbeit zu Grunde liegende SOC-Regelung gibt in jedem Fahrzeugbetriebspunkt eine optimierte Lade- bzw. Entladeleistung vor [159, 137]. Dieser Ansatz ermöglicht die Berücksichtigung des aktuellen Fahrzeugzustands ohne jedoch eine rechenintensive Online-Optimierung auf dem Steuergerät implementieren zu müssen.

Die Energieeffizienz des Ladezustandsmanagements wird mithilfe der spezifischen Verbrauchsänderung nach Gleichung 3.9 bewertet. Diese setzt die Differenz der Kraftstoffmassenströme zweier Betriebspunkte ins Verhältnis zur Batterieleistung.

$$b_{LPV} = \left| \frac{\dot{m}_{LPV} - \dot{m}_{bas}}{P_{bat}} \right| \left[ \frac{g}{kWh} \right] \quad (3.9)$$

Dabei ist  $\dot{m}_{LPV}$  bzw.  $\dot{m}_{bas}$  der Kraftstoffmassenstrom mit bzw. ohne Lastpunktverschiebung und  $P_{bat}$  die Batterieleistung bei verschobenen Lastpunkt. Für eine Lastpunktanhebung wird ausgehend von Gleichung 3.9 der Aufwand  $A_{LPAn}$  definiert, der die aufzuwendende Kraftstoffmenge zur Erzeugung einer Kilowattstunde Batterieenergie angibt (Gleichung 3.10).

$$b_{LPAn} = A_{LPAn} = \left| \frac{\dot{m}_{LPAn} - \dot{m}_{bas}}{P_{bat}} \right| \quad (3.10)$$

Dadurch können die „Kosten“ (oder der spezifische Mehrverbrauch) einer Lastpunktanhebung berechnet werden. Analog wird für eine Lastpunktabsenkung die Größe Nutzen  $N_{LPAb}$  eingeführt (Gleichung 3.11). Dieser definiert die Kraftstoffeinsparung bei Verwendung einer Kilowattstunde Batterieenergie für eine Absenkung des Lastpunktes.

$$b_{LPAb} = N_{LPAb} = \left| \frac{\dot{m}_{LPAb} - \dot{m}_{bas}}{P_{bat}} \right| \quad (3.11)$$

Für eine effiziente Regelung des SOC werden in Abhängigkeit vom aktuellen Ladezu-



stand ein maximaler Aufwand  $A_{max}$  sowie ein minimaler Nutzen  $N_{min}$  definiert. Dabei wird ein Laden der Batterie durch Lastpunktanhebung nur unter der Bedingung

$$A_{LPA_n} \leq A_{max} \quad (3.12)$$

zugelassen. Umgekehrt ist ein Entladen durch Lastpunktabsenkung nur möglich, wenn der Nutzen einen geforderten Mindestwert übersteigt (Gleichung 3.13).

$$N_{LPA_b} \geq N_{min} \quad (3.13)$$

Abbildung 3.11 zeigt schematisch die Grenzkurven für maximalen Aufwand  $A_{max}$  und minimalen Nutzen  $N_{min}$ . In den Randbereichen muss aus Gründen des Bauteilschutzes so-

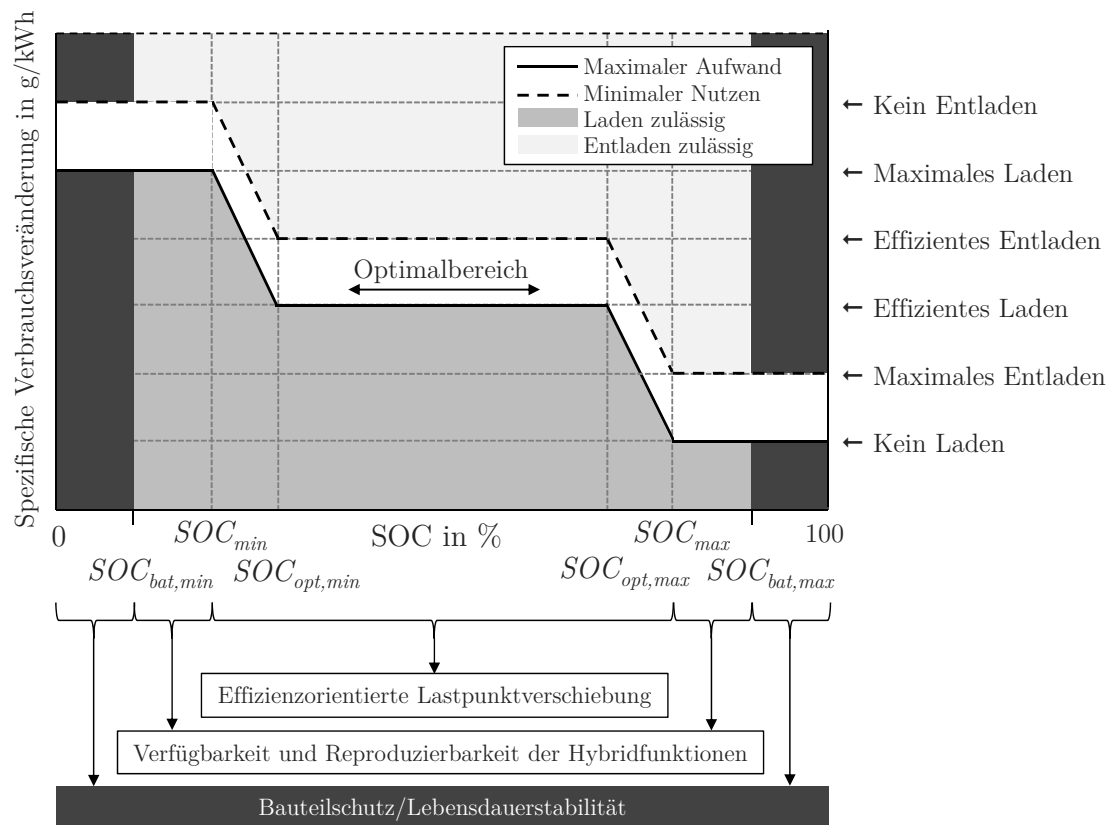


Abbildung 3.11: Definition eines maximal zulässigen Ladeaufwands  $A_{max}$  und minimal geforderten Nutzens  $N_{min}$  in Abhängigkeit vom SOC [179]

wie der Lebensdauerstabilität ein Unterschreiten der minimalen SOC-Grenze  $SOC_{bat,min}$  (Tiefentladung) bzw. ein Überschreiten der maximalen SOC-Grenze  $SOC_{bat,max}$  (Überladung) verhindert werden. Des Weiteren sollen die Hybridfunktionen reproduzierbar

### 3 Betrachteter Antriebsstrang

und zeitinvariant in allen Fahrzuständen verfügbar sein, so dass z.B. ein bestimmter minimaler Speicherenergieinhalt  $SOC_{min}$  für elektrisches Fahren angestrebt wird. Umgekehrt möchte man einen maximalen Speicherenergieinhalt  $SOC_{max}$  nicht überschreiten, um einen Vorhalt für eine mögliche Rekuperationsenergie bereit zu stellen.

Die Kennlinien für Aufwand und Nutzen lassen sich abhängig vom aktuellen Ladezustand der Hochvoltbatterie in drei wesentliche Bereiche einteilen:

- $SOC < SOC_{min}$ : Maximales Laden ermöglichen. Entladen verbieten.
- $SOC_{opt,min} < SOC < SOC_{opt,max}$ : Verbrauchseffizientes Laden und Entladen.
- $SOC > SOC_{max}$ : Laden verbieten. Maximales Entladen ermöglichen.

Zwischen  $SOC_{min}$  und  $SOC_{opt,min}$  wird bereits eine Lastpunktanhebung mit erhöhtem Aufwand zugelassen. Ein Entladen ist nur bei einem hohen Nutzenwert möglich. Umgekehrt kann im Bereich zwischen  $SOC_{opt,max}$  und  $SOC_{max}$  nur mit einem geringen Aufwand geladen werden und eine Lastpunktabsenkung ist bereits mit kleinen Nutzenwerten möglich. Das Aufwandsniveau im Optimalbereich zwischen  $SOC_{opt,min}$  und  $SOC_{opt,max}$  wird durch den optimalen Ladeaufwand  $A_{opt}$  definiert. Dieser hat den größten Einfluss auf das Ladeverhalten der Betriebsstrategie, da der Optimalbereich über einen großen SOC-Bereich aufgespannt ist.

Die SOC-Regelung gibt während des verbrennungsmotorischen Betriebs eine elektrische E-Maschinenleistung  $P_{EM,el}$  vor. Diese ist abhängig vom aktuellen Fahrzeugbetriebspunkt, der bei der betrachteten Parallelhybridtopologie aus Drehzahl und Drehmoment am Getriebeeingang  $(n_{getr,in}, M_{getr,in})$  abgeleitet werden kann. Die verbrauchseffizienten E-Maschinenleistungen für Lastpunktanhebung bzw. -absenkung werden offline bestimmt. Ein Algorithmus berechnet für alle möglichen Betriebspunkte am Getriebeeingang die E-Maschinenleistungen abhängig vom maximalen Aufwand bzw. minimalen Nutzen [137].

$$P_{EM,el,LPAa} = f(M_{getr,in}, n_{getr,in}, A_{max}) \quad (3.14)$$

$$P_{EM,el,LPAb} = f(M_{getr,in}, n_{getr,in}, N_{min}) \quad (3.15)$$

Bei der Berechnung werden die Wirkungsgrade von Verbrennungsmotor, E-Maschine, Leistungselektronik und Hochvoltspeicher berücksichtigt. Dadurch wird die gesamte Lade- bzw. Entladewirkungskette mit in die Effizienzbetrachtung einbezogen. In Abbildung 3.12 ist exemplarisch das Kennfeld der Ladeleistung für einen maximalen

Aufwand von  $270 \text{ g/kWh}$  abhängig von Drehzahl und Drehmoment am Getriebeeingang dargestellt. Der Verbrennungsmotor hat bei niedrigen Lasten einen schlechten Wir-

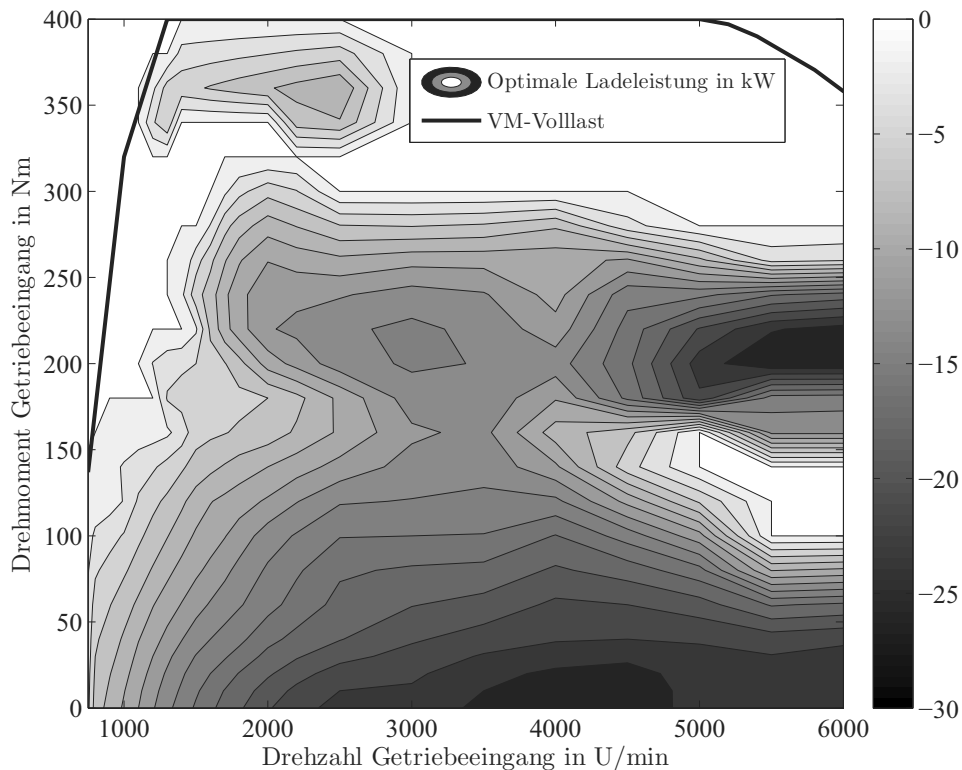


Abbildung 3.12: Gesamtwirkungsgradoptimierte elektrische Ladeleistung der E-Maschine in Abhängigkeit von Drehmoment und Drehzahl am Getriebeeingang für  $A_{max} = 270 \text{ g/kWh}$

kungsgrad (vgl. Abbildung 3.2). Folglich ist das Laden in diesen Bereichen effizienter, d.h. bei gleichem Aufwand kann im unteren Lastbereich eine höhere Batterieleistung generiert werden. Durch die Anhebung des Lastpunktes lässt sich der Verbrennungsmotor in einem günstigeren Betriebspunkt betreiben. Aber auch der Einfluss des E-Maschinenwirkungsgrades spiegelt sich im dargestellten Kennfeld wieder. Im Teillastbereich steigen die ermittelten Ladeleistungen mit zunehmender Drehzahl an. Die höchsten Werte sind im Bereich zwischen  $3000 \text{ U/min}$   $5000 \text{ U/min}$  erzielbar, in welchen die E-Maschine ihren besten Wirkungsgrad hat.

Die Ladeleistungskennfelder sind für verschiedene  $A_{max}$  auf dem Hybridsteuerggerät hinterlegt. Abhängig vom aktuellen maximalen Aufwand, welcher durch die Aufwandskennlinie nach Abbildung 3.11 bestimmt wird, kann so für jeden Betriebspunkt eine optimale E-Maschinenleistung vorgegeben werden. Analog existieren Entladeleistungskennfelder abhängig von  $N_{min}$  für die Lastpunktabsenkung. Die Stützstellen der

### 3 Betrachteter Antriebsstrang

Aufwands- und Nutzenkennlinie sind frei parametrierbar und können zudem durch Adaptionen verändert werden. Abhängig von der Fahrzeuggeschwindigkeit kann der Bereich, in dem kein Laden zugelassen bzw. ein maximales Entladen ermöglicht wird, vergrößert werden. Dadurch wird ein Vorhalt im Hochvoltspeicher für eine potenzielle Rekuperationsenergie geschaffen. Des Weiteren ist eine Anhebung des Aufwandsniveaus im Optimalbereich abhängig von der Bordnetzlast möglich. Das vorausschauende Energiemanagement kann die Lade- bzw. Entladekennlinie ebenfalls gezielt verschieben.

### 3.3.2 Elektrische Fahrentscheidung

Neben der SOC-Regelung hat die Entscheidung zum elektrischen Fahren den größten Einfluss auf den Kraftstoffverbrauch und die Fahrzeugcharakteristik. Hierbei stellt sich die Frage, in welchen Betriebspunkten e-Fahren bzw. VM-Fahren verbrauchsgünstiger ist. Daher wird im Folgenden für beide Fälle die entsprechende Wirkungsgradkette dargestellt (Abbildung 3.13). Die Energie für den elektrischen Vortrieb kann entweder durch Rekuperation oder Lastpunktanhebung bereitgestellt werden. Letztere Energiequelle steht dabei fast zu jeder Zeit zur Verfügung, während Rekuperationsphasen zeitlich begrenzt und abhängig vom Fahrprofil sind. Bei der folgenden Effizienzbetrachtung ist daher lediglich das e-Fahren aus Lastpunktanhebung von Bedeutung. Im reinen VM-

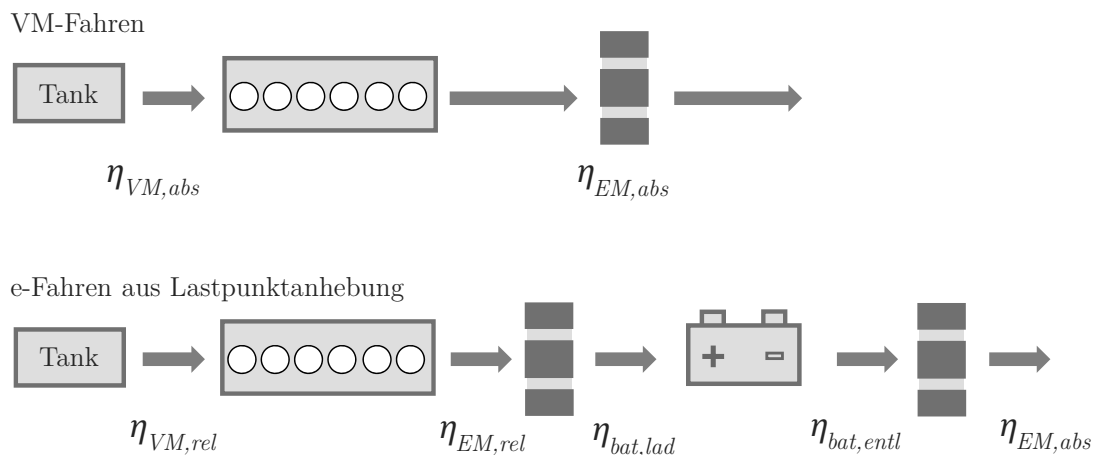


Abbildung 3.13: Wirkungsgradkette für VM-Fahren und e-Fahren aus Lastpunktanhebung

Betrieb summieren sich die Verluste von Verbrennungsmotor, E-Maschine und Getriebe. Dementsprechend ist der absolute Wirkungsgrad der Einzelkomponenten entscheidend. Beim e-Fahren aus Lastpunktanhebung entstehen zum einen Verluste durch den elektrischen Vortrieb. Diese setzen sich zusammen aus den Energieverlusten beim Entladen

der Batterie sowie den E-Maschinen- und Getriebeverlusten. Zum anderen müssen die Verluste bei der Erzeugung der elektrischen Energie über Lastpunktanhebung eingerechnet werden. Hier wird der relative Wirkungsgrad vom Verbrennungsmotor  $\eta_{VM,rel}$  und der E-Maschine  $\eta_{EM,rel,gen}$  verwendet, da lediglich die zusätzlich anfallenden Verluste interessieren. Zudem ist der Ladewirkungsgrad der Batterie  $\eta_{bat,lad}$  zu berücksichtigen.

Mithilfe der in Abschnitt 3.1 erläuterten Willans-Linien von Verbrennungsmotor und E-Maschine (inkl. Leistungselektronik) lassen sich die beiden Wirkungsgradketten als Willans-Geraden darstellen (Abbildung 3.14) (vgl. [17]).

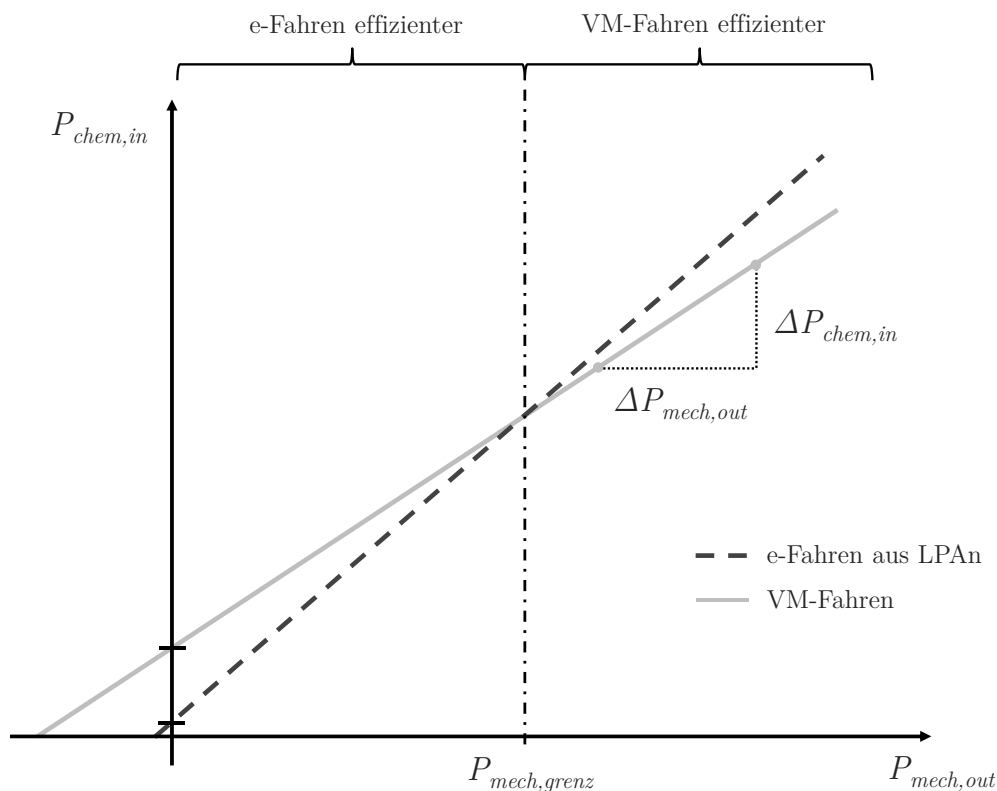


Abbildung 3.14: Qualitative Willans-Darstellung für die e-Fahrentscheidung

Die beiden Geraden beschreiben jeweils das Verhältnis von eingesetzter chemischer Energie  $P_{chem,in}$  zur mechanischen Ausgangsleistung am Getriebeausgang  $P_{mech,out}$  bei einer konstanten Drehzahl. Die Grundverluste, welche am Schnittpunkt der Geraden mit der Ordinate ablesbar sind, fallen für den reinen VM-Betrieb deutlich höher aus als beim e-Fahren aus Lastpunktanhebung. Der größte Verbrauchsvorteil ergibt sich folglich im Fahrzeugstillstand, da durch Abschalten des Verbrennungsmotors die Grundverluste eingespart werden können. Die Geradensteigungen spiegeln die Wirkungsgradketten aus Abbildung 3.13 wieder. Die Willans-Gerade für e-Fahren aus Lastpunktanhebung

### 3 Betrachteter Antriebsstrang

steigt aufgrund der längeren Wirkungsgradkette und den damit verbundenen höheren lastabhängigen Verlusten stärker an als die Gerade für VM-Fahren. Der Schnittpunkt beider Geraden definiert die Grenzleistung  $P_{mech,grenz}$  bis zu der e-Fahren energetisch günstiger ist als VM-Fahren. Liegt der Antriebswunsch über der Grenzleistung, ist der rein verbrennungsmotorische Betrieb vorteilhafter hinsichtlich des Kraftstoffverbrauchs.

Mit der Effizienzgrenze lässt sich ein möglicher e-Fahrbereich für das Fahrzeug als Beschleunigung oder Radmoment über Geschwindigkeit darstellen (Abbildung 3.15). Die

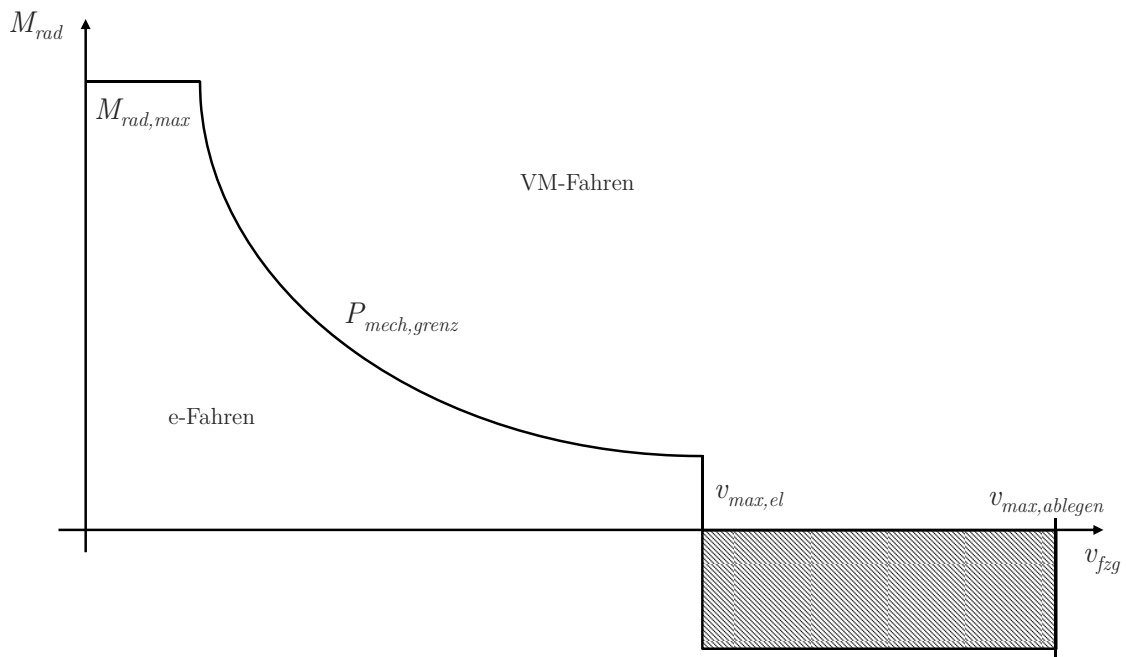


Abbildung 3.15: Abgrenzung des elektrischen und verbrennungsmotorischen Fahrbereichs anhand einer e-Fahrkennlinie

e-Fahrkennlinie dient der energetischen Betriebsstrategie als Entscheidungsgrundlage für einen elektrischen oder verbrennungsmotorischen Fahrbetrieb und ist im Zugbetrieb durch drei Parameter charakterisiert. Das maximale Radmoment für e-Fahren  $M_{rad,max}$  resultiert aus dem Maximalmoment der E-Maschine und wirkt nur im unteren Geschwindigkeitsbereich begrenzend. Ansonsten triggert die maximale e-Fahrleistung am Getriebeeingang  $P_{mech,grenz}$  oder die maximale e-Fahrgeschwindigkeit  $v_{max,el}$  den Zustand des Verbrennungsmotors. Im Schubbetrieb wird eine zusätzliche Geschwindigkeitsschwelle  $v_{max,ablegen}$  definiert, unterhalb dieser der Verbrennungsmotor abgeschaltet wird. Im Bereich zwischen  $v_{max,el}$  und  $v_{max,ablegen}$  ist demnach kein e-Fahren möglich, jedoch wird im Schubbetrieb der Verbrennungsmotor abgelegt.

## 3.4 Validierung des Prüfstands

Am vorgestellten Antriebsprüfstand kann das Zusammenspiel der Antriebskomponenten und Steuergeräte im realen Systemverbund in definierten Fahrmanövern erprobt und abgesichert werden. Neben generellen Funktions- und Schnittstellentests eignet sich die Plattform auch für spezielle Untersuchungen z.B. hinsichtlich des verbrennungsmotorischen Zustarts [215] oder der Effizienzbetrachtung der Lastpunktverschiebung [162]. Für eine energetische Bewertung unterschiedlicher Betriebsstrategieparametrierungen am Prüfstand muss dieser in der Lage sein, alle Betriebsarten und Systemzustände des realen Antriebsstrangs darzustellen.

Abbildung 3.16 zeigt beispielhaft einen am Antriebsprüfstand gefahrenen NEFZ<sup>16</sup>. Der Versuch wird von der Prüfstandsbedienwarte (vgl. Abbildung 3.8) aus gesteuert und überwacht. Im oberen Teilbild ist die an das Fahrermodell vorgegebene Sollgeschwindigkeit sowie die aus dem Prüfstandsgelenkwellenmoment berechnete virtuelle Istgeschwindigkeit dargestellt (vgl. Abbildung 3.9). Das Fahrermodell bewegt sich dabei innerhalb der zugelassenen Toleranz von  $\pm 2 \text{ km/h}$  [189]. Das zweite und dritte Teilbild visualisieren den Drehmomenten- und Drehzahlverlauf von Verbrennungsmotor und E-Maschine. Anhand der VM-Größen Moment  $M_{VM}$  und Drehzahl  $n_{VM}$  lassen sich die elektrischen und hybridischen Fahrphasen voneinander abgrenzen. Der e-Fahrbereich ist, wie im vorhergehenden Abschnitt 3.3.2 beschrieben, applikativ durch eine e-Fahrkennlinie definiert. Im Beispiel werden elektrische Antriebsleistungen bis zu 10 kW und eine maximale Geschwindigkeit von  $v_{max,el} = 55 \text{ km/h}$  zugelassen. Der Verbrennungsmotor läuft zu Testbeginn aufgrund der Katheizphase bei kaltem Motor auch im Fahrzeugstillstand ( $n_{VM} > 0$ ). Die jeweiligen Übergänge zwischen e-Fahren und VM-Fahren sind durch den Zustart bzw. den Ablegevorgang definiert. Im hybridischen Fahrbetrieb liegen die beiden Drehzahlen nahezu übereinander, jedoch kann drehzahlabhängig eine geringe Abweichung beobachtet werden. Dieses ist auf einen definierten Drehzahlschlupf an der Trennkupplung zurückzuführen, welcher aus Komfortgründen eingestellt wird. Die Lastpunktanhebung bei VM-Betrieb lässt sich am negativen E-Maschinenmoment erkennen. Dieses ist in der Regel aus Akustik- und Schwingungskomfortgründen abhängig von der Drehzahl auf  $\leq 100 \text{ Nm}$  limitiert. Die Rekuperationsphasen lassen sich in Schub- und Bremsrekuperation mit bzw. ohne laufenden Verbrennungsmotor unterteilen. Die Schubrekuperation (Fahr- und Bremspedal nicht getreten) hat im gezeigten Beispiel den größten Zeit- und Energieanteil. Die Bremsrekuperation ermöglicht höhere generatorische E-Maschinenmomente in den Verzögerungsphasen bei getretenem

---

<sup>16</sup>Neuer europäischer Fahrzyklus

### 3 Betrachteter Antriebsstrang




Abbildung 3.16: Zeitverläufe im NEFZ am Antriebsprüfstand

Bremspedal. Teilbild 4 zeigt den Verlauf des Ladezustands der Hochvoltbatterie  $SOC_{rel}$ . Der vorliegende Test weist eine ausgeglichene Ladebilanz des Hochvoltspeichers auf.

Eine messdatenbasierte Energie- und Betriebszustandsauswertung ermöglicht eine exakte Aufschlüsselung der Energieflüsse im hybriden Antriebsstrang. Dadurch können verschiedene Messungen von Prüfstand und Fahrzeug verglichen und bewertet werden. Tabelle 3.4 zeigt die wichtigsten Vergleichsgrößen für die Bewertung der energetischen Betriebsstrategie am Beispiel des oben aufgeführten NEFZ-Zyklus vom Antriebsprüfstand und einem Test vom Fahrzeugrollenprüfstand. Die automatisierte Auswertung kann über ein Matlab-Skript gestartet werden und ist ein wichtiges Hilfsmittel zur Analyse von Messungen und zur Beurteilung verschiedener Applikationsdatensätze.



		Prüfstand	Fahrzeug
Fahrprofil	Zeit in s	1180	1180
	Durchschnittsgeschw. in km/h	33.6	32.9
	Wegstrecke in km	11.01	10.79
State of Charge	Start SOC (rel.)	0.896	0.871
	End SOC (rel.)	0.887	0.889
	Delta-SOC in Wh	-5.6	+11.1
Elektrische Energie in Wh	e-Fahren	554	531
	Lastpunktanhebung	434	411
	Lastpunktabsenkung	0	0
	Zustart	43	39
	Ablegen	13	14
	Rekuperation	234	221
	Boost	6	3
	Bordnetz	145	138
Zeitanteile Betriebsarten in %	e-Fahren	32.7	31.5
	Lastpunktanhebung	28.1	29.6
	Lastpunktabsenkung	0	0
	Zustart	1.0	0.9
	Ablegen	0.9	0.9
	Rekuperation	12.9	13.1
	Boost	0.4	0.2
	MSA	22.1	21.9
Verbrauch in $l/100\text{km}$	Messanlage Prüfstand	6.59	-
	CO <sub>2</sub> -Messung Rollenprüfstand	-	6.67
Zustartanzahl		10	10
Temperaturen in °C	Motor (Start...End)	26 – 85	27 – 88
	E-Maschine (Start...Ende)	29 – 85	33 – 91
	Getriebe (Start...Ende)	29 – 50	31 – 52
Zeitanteil Gänge in %	1. Gang	30.8	31.0
	2. Gang	10.5	10.6
	3. Gang	4.5	4.7
	4. Gang	5.9	6.0
	5. Gang	14.6	13.9
	6. Gang	4.7	5.1
	7. Gang	10.8	10.3
	8. Gang	18.2	18.4

Tabelle 3.4: Auswertung von Fahrzeug- und Prüfstandsmessung im NEFZ-Zyklus

### 3 Betrachteter Antriebsstrang

Neben allgemeinen Informationen wie z.B. die Komponententemperaturen oder die SOC-Bilanz gibt die Auswertung einen Überblick über Zeit- und Streckenanteile<sup>17</sup> der Betriebsarten. Ferner erfolgt eine Auflistung der Energieverteilung verschiedener Betriebsmodi sowie der Gangwahl. Jeder Messzeitpunkt lässt sich durch die gezielte Auswertung der Systemzustände eindeutig zu einem Betriebsmodus zuordnen. Die aufgeführten Vergleichsgrößen werden in gleicher Form auch im Simulationsmodell berechnet und dienen später als Abgleich zwischen Messung und Simulation.

Die in Tabelle 3.4 gegenübergestellten Messungen von Prüfstand und Fahrzeug zeigen eine sehr gute Übereinstimmung aller Größen. Der Prüfstand bildet das Fahrzeug für eine Bewertung der Betriebsstrategieapplikation hinreichend genau ab. Mit dem vorgestellten Prüfstandskonzept können aussagekräftige Kraftstoffverbrauchsangaben für das spätere Fahrzeug generiert werden. Entscheidend ist die hohe Reproduzierbarkeit von Fahrversuchen durch die Möglichkeit der Prüfstandskonditionierung und die Minimierung des Fahrereinflusses. Der Prüfstand erlaubt damit die Validierung der in der Simulation optimierten Parametersätzen am realen Antriebsstrang unter realitätsnahen Bedingungen.

---

<sup>17</sup>Die Streckenanteile sind nicht in der Tabelle dargestellt.

# Kapitel 4

## Methode zur Optimierung und Applikation der Betriebsstrategie

Das Ziel der Arbeit war die Entwicklung einer Methodik zur Optimierung und Parametrierung der Betriebsstrategie von Hybridfahrzeugen im Serienentwicklungsprozess (Abschnitt 1.3). Berücksichtigung fanden dabei folgende Anforderungen und Rahmenbedingungen:

- Implementierung der Betriebsstrategiefunktionen inklusive Parametrierung für ein identisches Systemverhalten von Simulation und realem Antriebsstrang
- Leichte Austauschbarkeit der Hybridfunktionen im Laufe des Entwicklungsprozesses
- Modularer Aufbau des Simulationsmodells; Anwendung auf verschiedene Fahrzeugkonzepte
- Akzeptable/Angemessene Berechnungs- und Simulationszeiten
- Vergleichbarkeit verschiedener Ergebnisse hinsichtlich definierter Kriterien wie z.B. Kraftstoffverbrauch
- Einfache Übertragbarkeit der Parametrierung auf andere Entwicklungsplattformen (Antriebsprüfstand, Fahrzeugversuchsträger)

Im Folgenden wird der Entwicklungsansatz sowie die dafür verwendete Simulationsumgebung vorgestellt und erläutert.

## 4.1 Simulationsumgebung

Das zentrale Element der entwickelten Applikationsmethode ist eine Simulationsumgebung, welche in Matlab/Simulink [185] aufgebaut wurde. Das Hauptargument für die Verwendung der signalorientierten (kausalen) Modellierung in Matlab/Simulink war die Entwicklung der Steuergerätfunktionen der Betriebsstrategie mit eben dieser Modellierungssprache.

Prinzipiell lassen sich zwei Methoden – die dynamische<sup>1</sup> und die quasistationäre<sup>2</sup> Simulation – zur Berechnung des hybriden Antriebsstrangs unterscheiden [90, 174]. Bei der Rückwärtssimulation werden ausgehend von einem vorgegebenen Fahrzyklus die Energie- und Leistungsflüsse im Antriebsstrang zurückgerechnet (Abbildung 4.1). Aus




Abbildung 4.1: Prinzip der quasistationären Simulation (Rückwärtssimulation)

dem Fahrprofil, welches durch Geschwindigkeit und Steigung definiert ist, kann über die Berechnung der Fahrwiderstände<sup>3</sup>

$$F_{wid} = F_{luft} + F_{roll} + F_{steig} + F_a \quad (4.1)$$

<sup>1</sup>Vorwärtssimulation

<sup>2</sup>Rückwärtssimulation

<sup>3</sup>Luft-, Roll-, Beschleunigungs- und Steigungswiderstand

zunächst ein Sollmoment und eine Soll Drehzahl an den Rädern mithilfe des dynamischen Reifenradius  $r_{dyn}$  berechnet werden.

$$M_{rad} = F_{wid} r_{dyn} \quad (4.2)$$

$$n_{rad} = \frac{v_{fzg,soll}}{r_{dyn}} \frac{60}{2\pi} \quad (4.3)$$

Unter Berücksichtigung der Verluste und Übersetzungen von Hinterachsgetriebe (HAG) und Automatikgetriebe (Gangvorgabe) lässt sich die Drehzahl und das Drehmoment am Getriebeeingang berechnen. Letzteres ergibt sich entsprechend der Hybridbetriebsstrategie (SOC-Regelung, e-Fahr-Entscheidung, Boost, Rekuperation) als Summe aus Verbrennungsmotor- und E-Maschinenmoment. Der verbrauchte Kraftstoff kann mit dem Drehmoment und der Drehzahl des Verbrennungsmotors über ein Kraftstoffmassenstromkennfeld für den jeweiligen Fahrzyklus ermittelt werden. Das elektrische System (HV-Speicher, EKMV, PWR und DC/DC) ist über die E-Maschine mit dem mechanischen Antrieb gekoppelt. Die Systemspannung wird vorwärts gerechnet, während der Strom rückwärts ermittelt wird.

Im Vergleich dazu wird das Verhalten des Antriebsstrangs bei der dynamischen Simulation durch ein System von nichtlinearen Differentialgleichungen beschrieben. Ein Fahrermodell regelt über Gas- bzw. Bremspedal die Abweichung zwischen der Sollgeschwindigkeit aus dem Fahrzyklus und der berechneten Istgeschwindigkeit des Fahrzeugs (Abbildung 4.2). Das Drehmoment an den einzelnen Antriebsstrangkomponenten wird in diesem Fall vorwärts, als Reaktion auf den Fahrerwunsch, berechnet. Aus dem sich unter Berücksichtigung der Antriebsstrangverluste ergebenden Radmoment kann die Antriebskraft am Rad  $F_{rad}$  berechnet werden:

$$F_{rad} = \frac{M_{rad}}{r_{dyn}} \quad (4.4)$$

Unter Zuhilfenahme der resultierenden Kraft  $F_{res}$ , welche die Fahrwiderstände berücksichtigt, kann schließlich eine Geschwindigkeitsänderung  $\frac{dv}{dt}$  bestimmt werden (Gleichung 4.5).

$$F_{res} = F_{rad} - F_{wid} \quad (4.5)$$

Die resultierende Drehzahl wird für jede Komponente rückwärts berechnet.

Durch die Vorwärtssimulation lässt sich das dynamische Verhalten des Antriebs

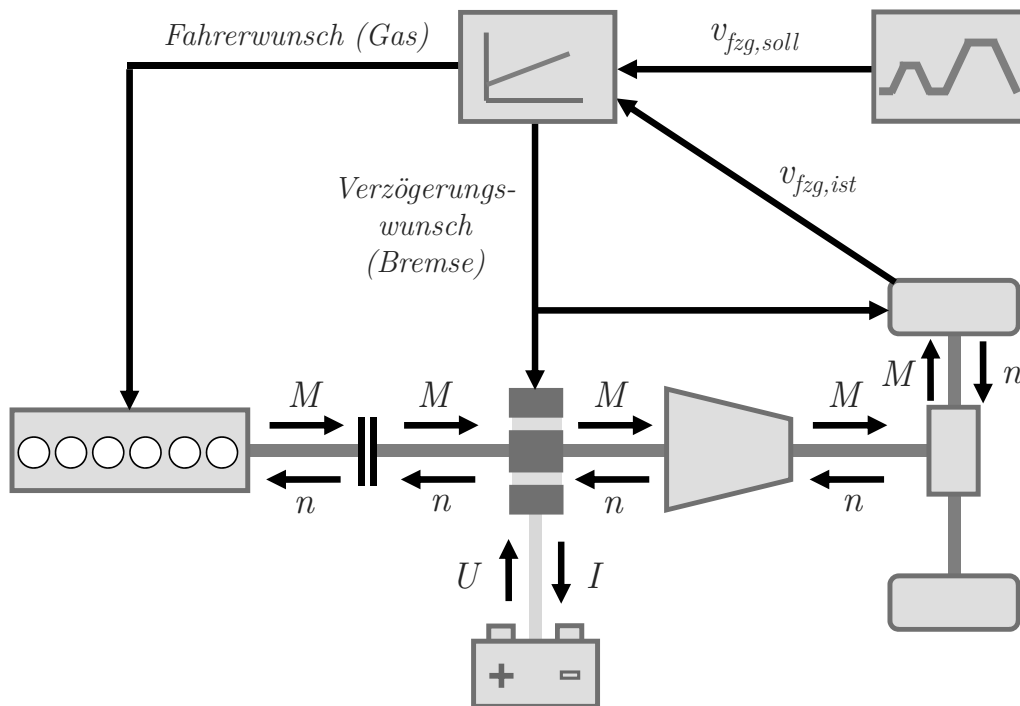


Abbildung 4.2: Prinzip der dynamischen Simulation (Vorwärtssimulation)

realitätsnah abbilden. Des Weiteren können unterschiedliche Fahrertypen betrachtet werden, da die Fahrzeugreaktion direkt berechnet wird. Die Rückwärtssimulation ist in der Regel zeiteffizienter. Es wird kein zusätzliches Fahrermodell benötigt und die Komponenten können im einfachsten Fall über Kennfelder (Wirkungsgradverluste) beschrieben werden. Als weiterer Vorteil der quasistationären Simulation ist die Stabilität der Berechnung aufzuführen, da im Vergleich zur dynamischen Modellierung kein geschlossener Regelkreis vorliegt. Nachteilig ist bei der quasistationären Modellierung jedoch die Anfälligkeit für ein Fehlverhalten im simulierten Antriebsstrang, wenn der gewünschte Sollgeschwindigkeitsverlauf die eigentliche Systemleistung und/oder -dynamik übersteigt. Die betrachteten gesetzlichen Verbrauchszyklen bewegen sich alle innerhalb der statischen und dynamischen Systemgrenzen, so dass hier vorrangig die quasistationäre Simulation Anwendung findet.

#### 4.1.1 Simulationskonzept

Das im Rahmen dieser Arbeit aufgebaute Modell ermöglicht sowohl eine quasistationäre als auch eine dynamische Simulation und wird im Folgenden näher erläutert. Wie bereits erwähnt liegt das Modell der Steuergerätefunktion als Simulink-Modell vor. Darauf

aufbauend wird die in Abbildung 4.3 dargestellte Simulationsstruktur gewählt. Das Hybridsteuergerät<sup>4</sup> beinhaltet die Funktionen der energetischen Betriebsstrategie wie die in Abschnitt 3.3 vorgestellte Ladezustandsregelung oder die elektrische Fahrentscheidung. Daneben existieren u.a. I/O-Module für die Vorverarbeitung von Eingangssignalen

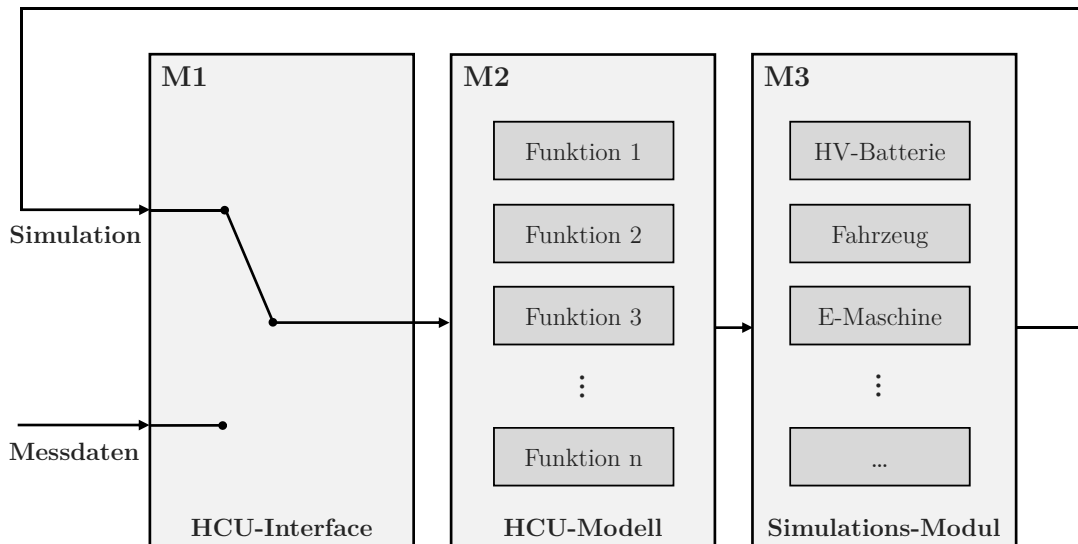


Abbildung 4.3: Simulationsframework für die Betriebsstrategieoptimierung (vgl. [178, 177])

und die Bildung der Ausgangssignale, ein Hybridmanager zur zentralen Steuerung der Betriebsarten und Umsetzung der verschiedenen Fahrmodiausprägungen sowie ein Leistungskordinator für die Priorisierung und Begrenzung von Antriebs- und Lastpunktverschiebungsleistung. Zusätzlich sind Sicherheits- und Überwachungsfunktionen für verschiedene Fehlerfälle sowie Diagnosefunktionen implementiert. In Summe umfasst das gesamte HCU-Modell ca. 15000 Verstellwerte (Festwerte, Kennlinien und Kennfelder), welche im Laufe des Entwicklungsprozesses parametrisiert werden müssen. Für die Simulation muss dabei nicht zwingend das gesamte HCU-Modell verwendet werden. Der Aufbau erlaubt die Berechnung einzelner Betriebsstrategiefunktionen beliebiger Kombination. Ermöglicht wird das durch ein variables Interface-Modul (Abbildung 4.3), welches über ein Matlab-Skript erzeugt werden kann. Das Skript generiert zudem die komplette Busstruktur der Simulationsumgebung abhängig von den ausgewählten HCU-Modulen. Dabei werden die folgenden Schritte abgearbeitet:

1. Klassifizierung aller Signale des HCU-Moduls als *intern* oder *extern*

<sup>4</sup>Hybrid Control Unit (HCU)

2. Bereitstellung der externen Signale durch das Interface-Modul durch
  - a) Simulation und/oder
  - b) Messdaten
3. Generierung der Busstruktur (Simulations- und Messdatenbus, Eingangs- und Ausgangsbus des HCU-Modells)

Das Interface-Modul fungiert in der realen Software als Schnittstelle zu den Low-Level-Funktionen, welche u.a. die Kommunikation mit anderen Steuergeräten (VM, Getriebe, HV-Speicher, usw.), das Einlesen von Sensordaten sowie die Ansteuerung der Aktoren koordinieren.

Abhängig vom gewählten Simulationsmodul ergeben sich drei unterschiedliche Anwendungsmöglichkeiten bzw. Simulationsmodi für das Framework:

**Stimuli-Mode** Es ist kein Simulationsmodul angebunden. Damit werden alle externen HCU-Signale über Messdaten bereitgestellt. Die Variante eignet sich z.B. zur gezielten Fehleranalyse einzelner HCU-Prozessblöcke oder zur Funktionsentwicklung. Voraussetzung ist jedoch immer das Vorhandensein aller relevanten HCU-Signale in einer Messdatei.

**Open-Loop-Mode** Die HCU-Eingangssignale werden bei dieser Variante sowohl durch Messdaten als auch durch die Simulation gespeist. Der Open-Loop-Mode entspricht einer Rückwärtssimulation (Abbildung 4.1). Der Fahrzyklus kann dabei zum einen innerhalb des Simulationsmoduls durch eine Sollgeschwindigkeit vorgeben werden, welche dann über die Fahrwiderstände in ein Sollradmoment überführt wird. Zum anderen kann das Sollmoment am Rad auch aus Messdaten eingelesen werden. Letztere Variante erlaubt das Nachfahren eines beliebigen Fahrprofils in der Simulation und ermöglicht damit eine Parameteroptimierung der Betriebsstrategie am realen Fahrzyklus.

**Closed-Loop-Mode** Im Closed-Loop-Mode (Vorwärtssimulation) werden alle HCU-Eingangssignale im Simulationsmodul generiert. Es werden keine Messdaten für die Simulation benötigt. Ein Fahrermodell regelt über ein Fahrerwunschkraftmoment die Differenz zwischen Soll- und Istgeschwindigkeit. Die Sollvorgabe kann auch aus einer Fahrzeugmessung in das Modell eingespeist werden.



## 4.1.2 Simulationsmodelle

Die wichtigsten Einzelmodelle des Simulationsmoduls werden im Folgenden beschrieben. Dabei liegt der Fokus auf den Modellen des Open-Loop-Modes, da dieser aufgrund der einfachen Implementierung und kurzen Rechenzeiten für die späteren Optimierungen Anwendung findet. Bei der Modellierung des Fahrzeugs ist nur die Längsdynamik von Bedeutung. Die Quer- sowie Vertikaldynamik wird bei der Betriebsstrategieoptimierung nicht betrachtet, da sie keinen wesentlichen Einfluss auf den Kraftstoffverbrauch haben.

### Fahrzeug

Das längsdynamische Fahrzeugmodell bildet lediglich die Fahrwiderstände gemäß Gleichung 4.1 ab. Der Beschleunigungswiderstand  $F_a$  setzt sich aus einem translatorischen und rotatorischen Anteil zusammen. Die translatorische Widerstandskraft  $F_{a,trans}$  berücksichtigt die zu beschleunigende Masse des Fahrzeugs  $m_{fzg}$ . Die Widerstandskraft der rotierenden Fahrzeugteile  $F_{a,rot}$  ergibt sich aus dem jeweiligen Massenträgheitsmoment und der jeweiligen Winkelbeschleunigung. Die Massenträgheitsmomente aller drehenden Teile werden auf die Antriebsachse bezogen und ergeben das gangabhängige reduzierte Massenträgheitsmoment  $\Theta_{red,i}$ . Mit dem dynamischen Reifenhalmmesser  $r_{dyn}$  folgt für den Beschleunigungswiderstand [128]:

$$\begin{aligned} F_a &= F_{a,trans} + F_{a,rot} \\ &= \left( m_{fzg} + \frac{\Theta_{red,i}}{r_{dyn}^2} \right) a_{fzg} \end{aligned} \quad (4.6)$$

Der Steigungswiderstand (Gleichung 4.7) wird für die Abbildung der gesetzlichen Fahrzyklen nicht benötigt. Für die Parametrierung der Hybridfunktionen, die Steigungs- und Gefälleinformationen nutzen, ist eine Vorgabe der Steigung über Zeit jedoch vorgesehen. Der Steigungswiderstand ergibt sich aus dem Fahrbahnwinkel  $\alpha$  und der Fahrzeugmasse zu:

$$F_{steig} = m_{fzg} g \sin\alpha \quad (4.7)$$

Für die Luftwiderstandskraft folgt mithilfe der Fahrzeugstirnfläche  $A_{stirn}$ , dem Luftwiderstandsbeiwert  $c_w$  und der Luftdichte  $\rho$ :

$$F_{luft} = c_w A_{stirn} \frac{\rho}{2} v_{rel}^2 \quad (4.8)$$

Die Relativgeschwindigkeit  $v_{rel}$  ist die Differenz aus Fahrzeug- und Anströmgeschwin-

digkeit. In den betrachtenden Untersuchungen wird ohne einen zusätzlichen Windwiderstand gerechnet, so dass  $v_{rel} = v_{fzg}$  gilt.

Für die Rollreibung ergibt sich mit dem geschwindigkeitsabhängigen Rollwiderstandskoeffizienten  $f_R(v_{fzg})$ :

$$F_{roll} = f_R(v_{fzg}) m_{fzg} g \cos\alpha \quad (4.9)$$

Für eine ausführliche Herleitung der Fahrwiderstände sei auf [128] verwiesen.

### Verbrennungsmotor

Es wird ein einfaches kennfeldbasiertes Modell des Verbrennungsmotors verwendet. Der Kraftstoffverbrauch wird über ein Kraftstoffmassenstromkennfeld (vgl. Abschnitt 3.1.1) als Funktion von effektiven Motordrehmoment und Motordrehzahl bestimmt.

$$\dot{m}_{kst} = f(n_{VM}, M_{VM,eff}) \quad (4.10)$$

Zusätzlich wird eine Schubabschaltung und der Leerlauf des Verbrennungsmotors für eine möglichst exakte Bestimmung des Kraftstoffverbrauchs modelliert. Die Volllastkennlinie und das Schleppmoment werden jeweils über drehzahlabhängige Kennlinien abgebildet. Der Momentenaufbau auf Basis des berechneten Fahrerwunschloments  $M_{VM,soll}$  wird über ein  $PT_1$ -Glied approximiert (Gleichung 4.11).

$$M_{VM,eff} = \frac{1}{T_{VM}s + 1} M_{VM,soll} \quad (4.11)$$

Weiterhin findet das Trägheitsmoment der rotierenden Massen des Verbrennungsmotors bei der Bestimmung des Beschleunigungswiderstands Berücksichtigung.

### E-Maschine und Leistungselektronik

Der elektrische Antrieb, bestehend aus E-Maschine und Leistungselektronik, wird ebenfalls kennfeldbasiert modelliert. Der Wirkungsgrad der elektrischen Komponenten wird über ein Verlustleistungskennfeld abhängig von Drehzahl, Drehmoment und Systemspannung abgebildet (vgl. Abschnitt 3.1.2). Sowohl das motorische als auch das generatorische E-Maschinenmoment werden abhängig von Drehzahl und Systemspannung begrenzt. Zusätzlich ist auch die Peak- und Dauerleistung des elektrischen Antriebs eine begrenzende Größe. Weiterhin wird die E-Maschine durch ihr Massenträgheitsmoment beschrieben.

## Trennkupplung und Getriebe

Das Getriebemodell wechselt abhängig von Drehzahl und Drehmoment am Rad das Übersetzungsverhältnis  $i_{getr}$  (Abschnitt 3.1.3).

$$i_{getr} = \frac{n_{getr,in}}{n_{getr,out}} \quad (4.12)$$

In Abhängigkeit von der Getriebeausgangsleistung und der Übersetzung gibt es Reibungsverluste im Getriebe. Zusätzlich entstehen Verluste beim Gangwechsel selbst, welche ebenfalls in Kennfeldern hinterlegt sind. Das Trägheitsmoment für die Berechnung des Beschleunigungswiderstands ist abhängig von der jeweiligen Gangstufe. Für das Hinterachsgetriebe mit konstantem Übersetzungsverhältnis werden ebenfalls drehzahl- und lastabhängige Verluste angesetzt.

Die Trennkupplung ermöglicht die vollständige Abkopplung des Verbrennungsmotors vom Abtrieb, wodurch ein rein elektrischer Fahrbetrieb dargestellt werden kann. Das Trennkupplungsmodell kennt lediglich die beiden Zustände „Kupplung offen“ und „Kupplung geschlossen“. Ist die Trennkupplung geöffnet (Verbrennungsmotor ist abgekoppelt) so wird ein zusätzliches drehzahlabhängiges Schleppmoment der Kupplung in

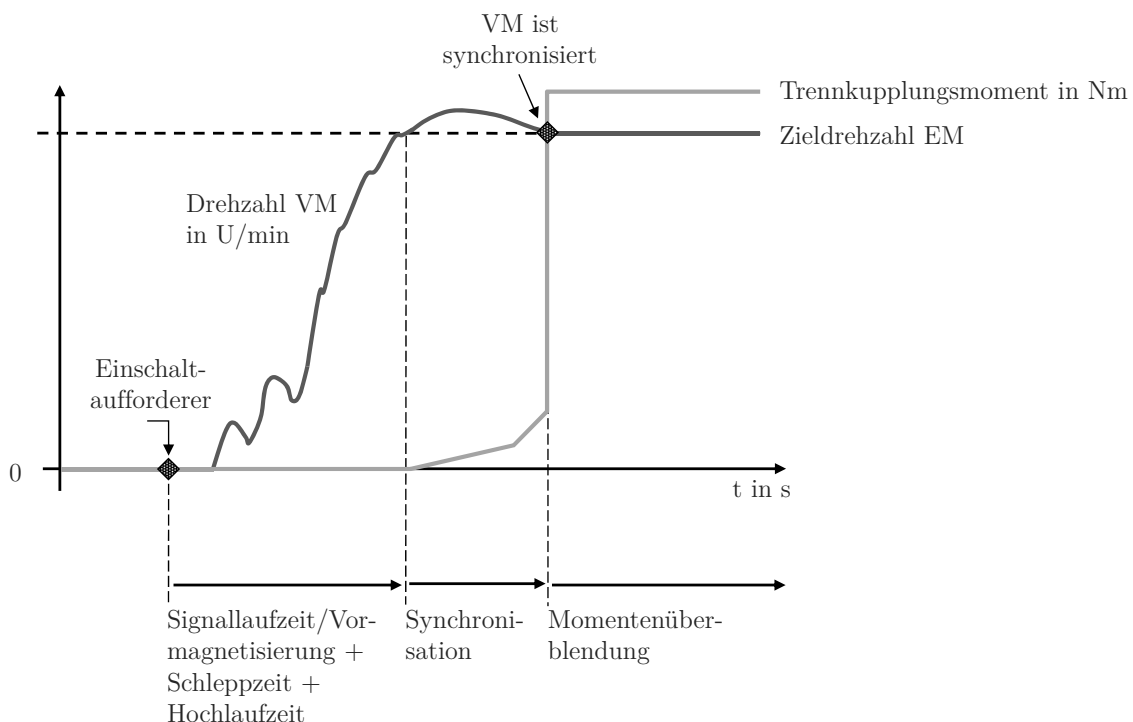


Abbildung 4.4: Schematischer Ablauf des Zustarts

der Simulation berücksichtigt.

Die beiden Zustände Zustart (Motor zustarten und ankoppeln) und Ablegen (Motor abkoppeln und ausschalten) bedürfen an dieser Stelle einer gesonderten Betrachtung. Beim Zustart müssen Verbrennungsmotor- und E-Maschinendrehzahl zunächst synchronisiert werden bevor die Kupplung geschlossen werden kann (Abbildung 4.4). Abhängig von der Synchronisationsdrehzahl fallen somit zusätzliche Verluste an. Des Weiteren müssen im Modell die Zeiten für das Anschleppen und Hochlaufen des Verbrennungsmotors sowie die Drehzahlsynchronisation berücksichtigt werden. Nach dem eigentlichen Schließen der Trennkupplung kann der Verbrennungsmotor zwar ein Drehmoment an den Abtrieb übertragen, dieses baut sich gemäß der angenommenen  $PT_1$ -Dynamik jedoch langsam auf, so dass die E-Maschine auch weiterhin ein motorisches Moment stellen muss (Momentenüberblendung). Auch das Abkoppeln und Ausschalten des Motors ist ein verlustbehafteter Vorgang, wenngleich mit deutlich geringeren Energieverlusten als beim Zustartvorgang.

Die Gangwechsel erfolgen abhängig von der Getriebeausgangsdrehzahl und dem gewünschten Abtriebsmoment. Hierfür sind unterschiedliche Sets an Schaltkennlinien für verbrennungsmotorisches und elektrisches Fahren im Getriebemodell hinterlegt. Die Betriebsstrategie beeinflusst folglich durch die elektrische Fahrentscheidung auch die Schalthäufigkeit.

### Hochvoltspeicher

Für den Hochvoltspeicher (vgl. Abschnitt 3.1.4) wird ein einfaches Ersatzschaltbildmodell (Abbildung 4.5) verwendet, welches das Spannungsverhalten an den Batterieklemmen beschreibt.

Die Batteriespannung  $U_{bat}$  ergibt sich zu:

$$U_{bat} = U_{OCV} + I_{ser}R_{ser} + I_{R,par}R_{par} \quad (4.13)$$

Mit den Gleichungen 4.14 - 4.16 kann das elektrische System beschrieben werden.

$$I_{R,par} = \frac{U_{R,par}}{R_{par}} \quad (4.14)$$

$$I_{R,par} = I_{bat} - I_C \quad (4.15)$$

$$U_{R,par} = U_C = \frac{1}{C_{par}} \int I_C dt \quad (4.16)$$

Die Parameter  $R_{ser}, R_{par}$  und  $C_{par}$  des Ersatzmodells sind eine nichtlineare Funktion

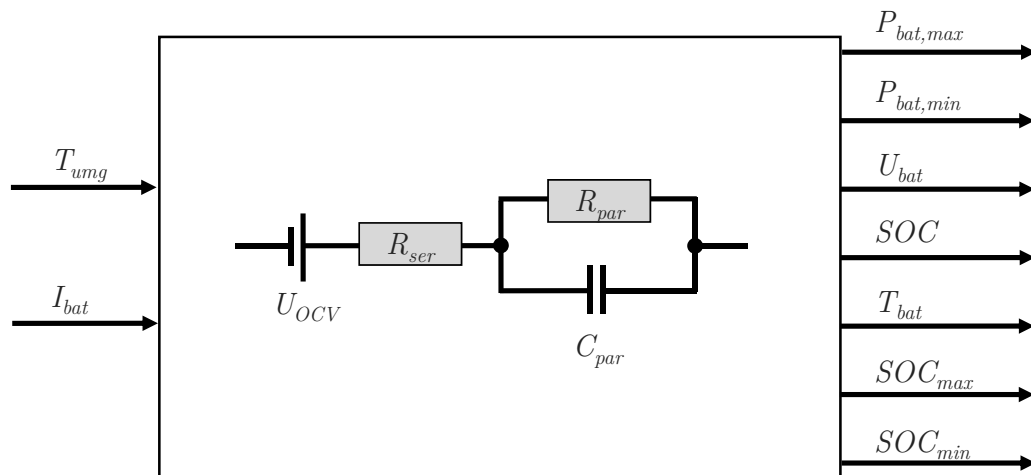


Abbildung 4.5: Modell des Hochvoltspeichers

von SOC, Klemmenstrom und Batterietemperatur. Sie wurden in experimentellen Messreihen ermittelt und die Ergebnisse sind als Kennfelder im Modell implementiert. Die Leerlaufspannung  $U_{OCV}$  in Abhängigkeit vom Ladezustand und Temperatur ist ebenfalls als Kennfeld hinterlegt.

Der SOC berechnet sich nach Gleichung 3.7 durch Integration des Klemmenstroms  $I_{bat}$ . Des Weiteren werden die maximale und minimale Batterieleistung ( $P_{bat,max}$  und  $P_{bat,min}$ ) abhängig von SOC, Temperatur sowie Strom- und Spannungsgrenzen berechnet. Die Leistungsgrenzen werden von der Betriebsstrategie bei der Leistungskoordination berücksichtigt. Ein einfaches thermisches Modell bestimmt abhängig von Außentemperatur und Batteriestrom die Batterietemperatur. Im Fahrzeug wird die Hochvoltbatterie bei Erreichen einer oberen Temperaturschwelle durch den EKVM gekühlt. In der Simulation wird in diesem Fall für eine festgelegte Zeitdauer, die sich aus dem unteren Hysteresewert der Speichertemperatur ergibt, eine konstante EKVM-Leistung vorgegeben. Der Einfluss der Hochvoltbatterietemperatur in der Energiebilanz ist für die in dieser Arbeit betrachteten Zyklen lediglich bei hohen elektrischen Fahrleistungen vorhanden.

### Elektrische Verbraucher

Neben der E-Maschine existieren mit dem DC/DC-Wandler und dem EKVM zwei weitere elektrische Verbraucher im Hochvoltbordnetz (Abbildung 3.1). Während der DC/DC-Wandler das Niedervoltbordnetz mit maximal 2.8 kW versorgt, kann der EKVM bis zu 5 kW Leistung für die Klimatisierung anfordern. Wie bereits erwähnt wird auch die Hochvoltspeicherkühlung durch den EKVM umgesetzt. Für den Klemmenstrom der

Hochvoltbatterie folgt damit:

$$I_{bat} = I_{EM} + I_{DC/DC} + I_{EKMV} \quad (4.17)$$

Die Leistung des EKMV und die 12 V-Bordnetzleistung kann variabel über die Zeit vorgegeben bzw. ereignisgesteuert verändert werden.

#### **Motor-Start-Stopp-Betriebsstrategie**

Im realen Fahrzeug wird die finale Entscheidung für einen Verbrennungsmotorstart bzw. -stopp auf dem Motorsteuergerät getroffen. Die energetische Betriebsstrategie (e-Fahrentscheidung, SOC-Regelung) kann dabei nicht alleine über den Verbrennungsmotorzustand entscheiden. So existieren z.B. zahlreiche komfort- und systembedingte Start- bzw. Stopp-Anforderungen im realen Antriebsstrang. Generell lassen sich die Anforderungen der Komponenten bzw. Funktionen hinsichtlich des Verbrennungsmotorzustands in Einschaltaufforderer und Abschaltverhinderer aufteilen. Einschaltaufforderer triggern unabhängig voneinander einen sofortigen Motorstart, falls dieser nicht aus einem anderen Grund bereits läuft. Dabei ist es egal, ob nur eine oder mehrere Zustartanforderungen anliegen (logische Oder-Verknüpfung). Im Gegensatz dazu können Abschaltverhinderer lediglich den Stopp des Motors unterbinden wenn dieser bereits läuft, jedoch keinen Zustart anfordern. Der Verbrennungsmotor kann nur abgestellt werden, wenn keine Abschaltverhinderer und keine Einschaltaufforderer gesetzt sind. Für die Betriebsstrategieapplikation wurde die Motor-Start-Stopp-Logik des Motorsteuergeräts im Simulationsmodul in einfacher Form nachgebildet. Als Einschaltaufforderer wurden in der Simulation

- kein e-Fahren (gebildet von der e-Fahr-Entscheidung)
- SOC zu niedrig/zu hoch (aus der SOC-Regelung)
- Momentengrenze E-Maschine
- Batterietemperatur zu niedrig/zu hoch

abgebildet. Für die Simulation relevante und umgesetzte Abschaltverhinderer sind

- SOC zu niedrig/zu hoch (aus der SOC-Regelung)
- Mindestlaufzeit des Verbrennungsmotors
- Gangwechsel (Komfortausschaltverhinderer vom Getriebe)

- Batterietemperatur zu niedrig/zu hoch
- On-Board-Diagnose-Anforderung
- Katalysatortemperatur zu niedrig.

### **Momentenkoordination**

Die Koordination der verschiedenen Momentenanforderungen im Antriebsstrang findet ebenfalls auf dem Motorsteuergerät statt. Folgende für die Betriebsstrategiesimulation relevanten Funktionalitäten werden im Simulationsmodul nachgebildet:

- Koordination und Begrenzung des gewünschten Lastpunktverschiebungsmoments
- Geschwindigkeits- und verzögerungsabhängige Begrenzung sowie Ein- und Ausblendung der Bremsrekuperation
- Berücksichtigung des Trennkupplungsstatus (offen, geschlossen) abhängig vom Verbrennungsmotorzustand (An, Aus)
- Überblenden von Verbrennungsmotor- und E-Maschinenmoment im Zustrart- bzw. Ablegevorgang
- Zusammenführung der Momentengrenzen von Verbrennungsmotor und E-Maschine sowie Gradientenbegrenzung
- Einrechnung des VM-Schleppmoments bei der Schubrekuperation
- Abbildung von Anfahr- und Anhaltevorgängen

### **Fahrzyklus**

Im Fahrzyklusmodell wird das Geschwindigkeits- und Höhenprofil des zu simulierenden Fahrprofils vorgegeben. Neben den gängigen gesetzlichen Fahrzyklen können auch Kundenfahrprofile in die Simulation eingebunden werden. Die Beispiele dieser Arbeit beziehen sich auf die gesetzlichen Zyklen NEFZ [146] und FTP-72<sup>5</sup> [190], welche für die Typzulassung in der EU bzw. in den USA Anwendung finden. Darüber hinaus wird als kundennahes Fahrprofil der „MUC-Stadtzyklus“ verwendet.

---

<sup>5</sup>Federal Test Procedure

## 4.2 Kombination von Simulation und Antriebsprüfstand im Applikationsprozess

Für die optimale Parametrierung und Absicherung der Betriebsstrategiefunktionen im laufenden Serienentwicklungsprozess wird die in Abbildung 4.6 dargestellte Methodik eingeführt. Das Simulationsframework aus Abschnitt 4.1.1 bildet das zentrale Element

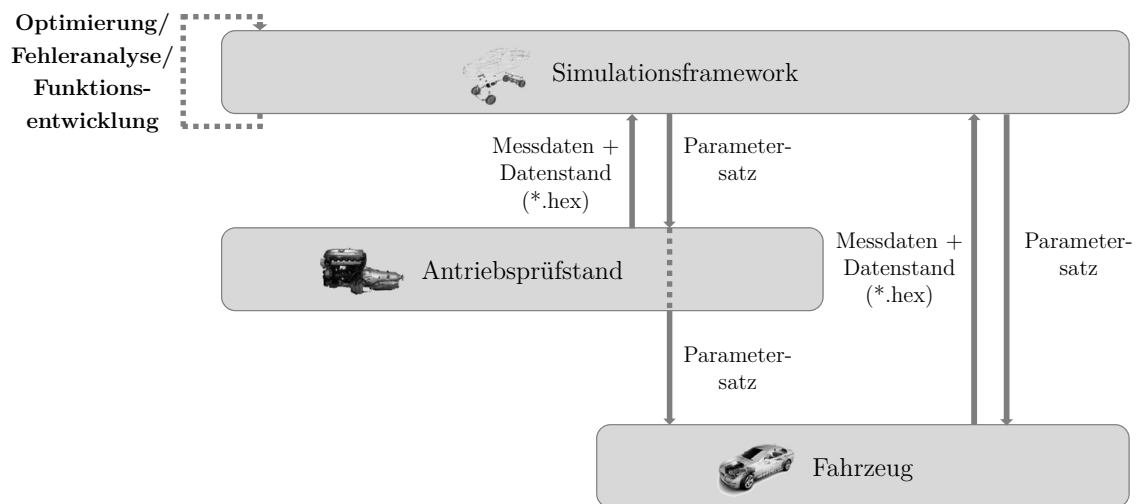


Abbildung 4.6: Schema der Betriebsstrategie-Applikationsmethode (vgl. [177])

für den Applikationsprozess. Mithilfe der Rückwärtssimulation (Open-Loop-Mode) ist es möglich eine Messung vom Antriebsprüfstand oder aus einem Fahrzeugversuchsträger nachzusimulieren. Dafür ist es zwingend notwendig in der Simulation zum einen den gleichen Programmstand, zum anderen den gleichen Datenstand wie am realen Antriebsstrang zu verwenden. Der Programmstand oder auch Programmcode enthält u.a. die codierten Funktionen und Algorithmen der Hybridfunktionen. Eine Funktionsänderung im HCU-Modell hat demnach einen neuen Programmstand zur Folge. Die gesamten Verstellwerte (frei konfigurierbare Daten) der HCU-Funktionen werden im Datenstand gespeichert. Ein Programmstand kann folglich mit verschiedenen Datenständen (Parametrierungsvarianten) gefahren werden. Das Simulationsframework erlaubt den einfachen Austausch von Datenständen über das hex-Datenformat. Der Programmcode kann direkt in Form der Simulink-Modelle eingebunden werden. Die Energiebilanz von Rückwärtssimulation und realer Messung kann anschließend verglichen werden. Ferner bietet sich eine Überprüfung der Verläufe der wichtigsten Systemgrößen wie z.B.



#### *4.2 Kombination von Simulation und Antriebsprüfstand im Applikationsprozess*

Drehzahlen, SOC oder E-Maschinenleistung an. Stimmen Messung und simulierte Werte überein, so kann der Ausgangsdatenstand mithilfe der Simulation hinsichtlich eines definierten Sollverhaltens angepasst oder auf Basis definierter Zielkriterien optimiert werden. Die Betriebsstrategie lässt sich damit losgelöst vom realen Antriebsstrang, aber an den realen Steuererätfunktionen, virtuell parametrieren.

Der in Abschnitt 3.2 vorgestellte Prüfstand dient anschließend zur Validierung der ermittelten Parametrierung am realen Antriebsstrang. Die modifizierten Daten können über das hex-Austauschdatenformat einfach im realen Steuergerät am Prüfstand oder direkt im Fahrzeug eingebunden werden. Der Prüfstand bietet als Validierungsplattform entscheidende Vorteile hinsichtlich der Reproduzierbarkeit von Fahrmanövern und -zyklen im Vergleich zum Fahrzeugversuchsträger. Durch eine gezielte Prüfstandskonditionierung können reproduzierbare Startbedingungen für die Tests geschaffen werden. Des Weiteren entfällt im Vergleich zum Fahrzeug der Fahrereinfluss durch Verwendung eines Fahrermodells.

## 4.3 Multikriterieller Optimierungsalgorithmus

In diesem Kapitel wird der in der vorliegenden Arbeit verwendete Optimierungsalgorithmus vorgestellt. Neben der Darstellung des Basisalgorithmus liegt der Fokus vor allem auf den vorgenommenen Anpassungen und Erweiterungen. In zahlreichen Veröffentlichungen haben sich evolutionäre Algorithmen bereits als effiziente Methode bei der Auslegung und Optimierung von Komponenten und Funktionen in Hybridantrieben erwiesen [27, 26, 93, 70, 130, 129, 39, 53, 94, 209, 210, 212, 13]. Auf Basis der Vorbetrachtungen in Abschnitt 2.4 hat sich der Autor für den Pareto-basierten genetischen Algorithmus NSGA-II entschieden. Dieser findet in zahlreichen der aufgeführten Veröffentlichung erfolgreich Verwendung und war des Weiteren vielfach Basis theoretischer Betrachtungen und Vergleiche (Abschnitt 2.4.4).

### 4.3.1 Basisalgorithmus NSGA-II

Die erste Version des NSGA wurde 1994 von Deb und Srinivas [181] vorgestellt und basierte auf einer Fitnessbewertung, welche nicht-dominierte Lösungsmengen bevorzugte. Gleichzeitig wurde durch eine „sharing“-Strategie die Diversität unter den Lösungen gesichert. Hauptkritikpunkte waren die fehlende Elitismusumsetzung, die schwierige Wahl des „sharing“-Parameters  $\sigma_{share}$  sowie die hohe Rechenkomplexität, insbesondere bei der Verwendung großer Populationen. Der elitäre NSGA-II, eine Weiterentwicklung des NSGA, verwendet einen modifizierten Sortieralgorithmus und benötigt keine zusätzliche Festlegung eines „sharing“-Parameters [50]. In der Arbeit wurde als Basis die reell codierte Variante des NSGA-II, welche als Open Source Matlab Code zur Verfügung steht, verwendet [175].

Abbildung 4.7 veranschaulicht den Rechenablauf des NSGA-II-Algorithmus. Dieser beginnt mit einer zufällig verteilten Startpopulation, deren Größe vom Nutzer zu Beginn der Optimierung festgelegt wird. Anschließend werden die Zielfunktionswerte der einzelnen Individuen durch die Simulation bestimmt. Das *non-dominated sorting* weist den Individuen im Zielfunktionsraum verschiedene Fronten zu. Alle nicht-dominierten Lösungen bilden die erste Front (vgl. Abschnitt 2.4.1). Individuen, welche der zweiten Front zugeordnet sind, werden nur von Lösungen der ersten Front dominiert. Die Sortierung wird fortgesetzt bis jede Lösung einer Front zugeteilt ist (Abbildung 4.8). Des Weiteren wird für jedes Individuum ein Distanzmaß, die sog. *crowding distance*, bestimmt. Die *crowding distance* für ein bestimmtes Individuum verwendet den normierten Abstand der zwei benachbarten Lösungen derselben Front. Dieser Abstand wird für jede Zielfunktion

### 4.3 Multikriterieller Optimierungsalgorithmus

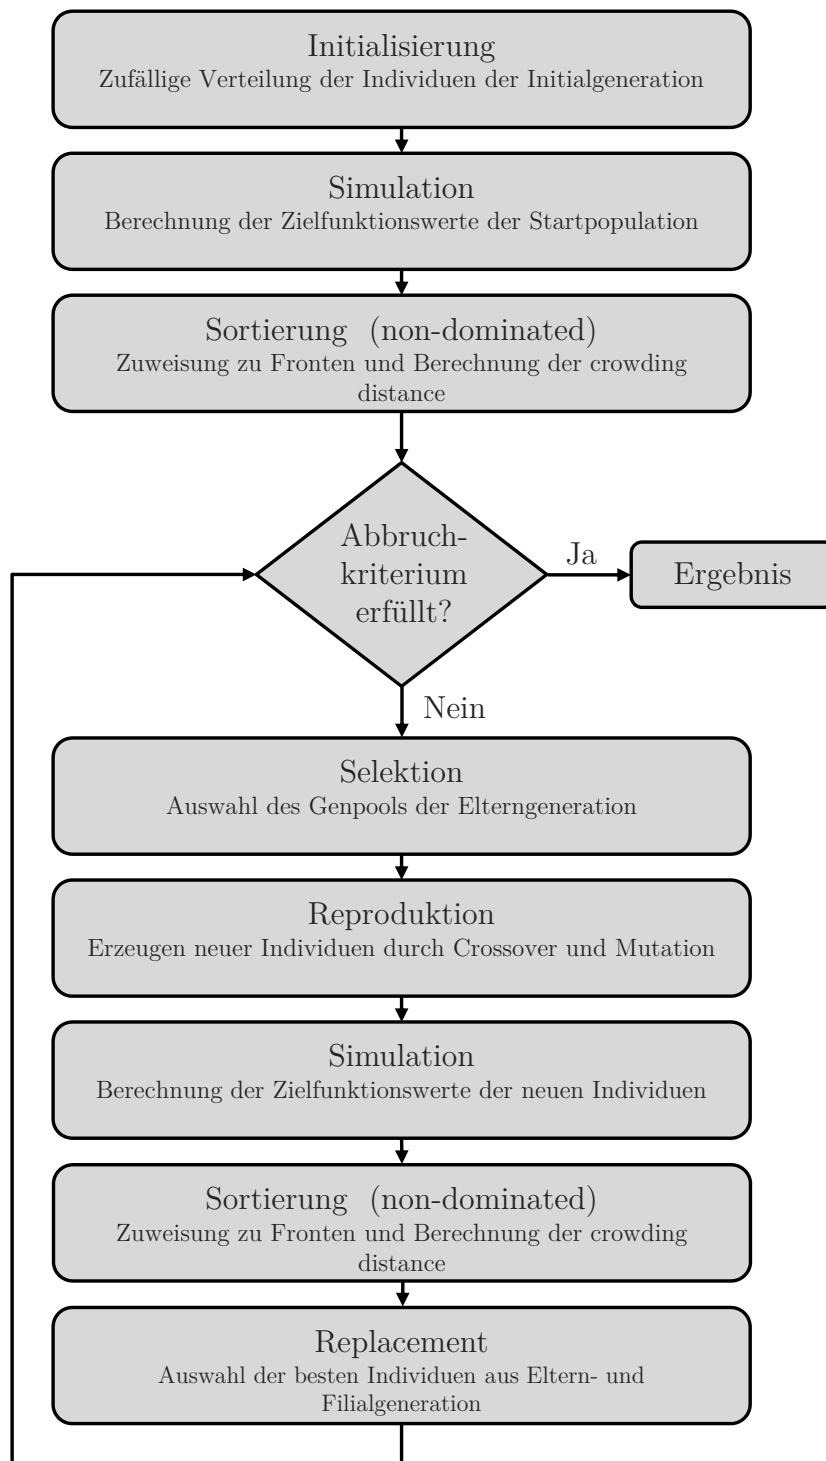


Abbildung 4.7: Ablaufplan des implementierten NSGA-II-Algorithmus (vgl. [26, 88])

separat bestimmt und schließlich über alle Zielfunktionen aufsummiert. Die Lösungen mit den jeweils höchsten und niedrigsten Zielfunktionswert einer Front bekommen einen




Abbildung 4.8: Einteilung nach Fronten zur Bestimmung der *crowding distance* [88, 50]

unendlichen Wert zugewiesen. Im zweidimensionalen normierten Zielfunktionsraum entspricht die *crowding distance* der Summe der beiden Seitenlängen des in Abbildung 4.8 dargestellten Rechtecks.

Der Selektionsprozess nutzt das Prinzip der Turnierselektion (*tournament selection*) in Kombination mit dem *crowded-comparison*-Operator zur Befüllung des Genpools für die Nachkommensbildung. Beim vorliegenden NSGA-II-Algorithmus treten zwei zufällig ausgewählte Individuen gegeneinander an, wobei das Individuum mit der niedrigeren Front gewinnt. Gehören die Lösungen der gleichen Front an, so wird die Lösung mit der größeren *crowding distance* bevorzugt [50]. Ist der Paarungspool vollständig gefüllt, werden im nächsten Schritt neue Individuen durch Rekombination und Mutation erzeugt.

Bei der Rekombination kommt der SBX-Operator zum Einsatz [44, 49]. Dabei werden aus zwei Eltern  $p_{1,k}$  und  $p_{2,k}$  zwei Kinder  $c_{1,k}$  und  $c_{2,k}$  erzeugt (Gleichung 4.18, 4.19).

$$c_{1,k} = 0.5 [(1 - \beta_k) p_{1,k} + (1 + \beta_k) p_{2,k}] \quad (4.18)$$

$$c_{2,k} = 0.5 [(1 + \beta_k) p_{1,k} + (1 - \beta_k) p_{2,k}] \quad (4.19)$$

Der Ausbreitungsfaktor  $\beta_k$  beschreibt das betragsmäßige Verhältnis des Abstands des  $k$ -ten Parameters beider Kinder zum Abstand des  $k$ -ten Parameters beider Eltern

und wird für den  $k$ -ten Parameter berechnet zu:

$$\beta_k(u_k) = \begin{cases} (2u_k)^{\frac{1}{\eta_c+1}}, & \text{wenn } u_k \leq 0.5 \\ \left(\frac{1}{2(1-u_k)}\right)^{\frac{1}{\eta_c+1}}, & \text{sonst.} \end{cases} \quad (4.20)$$

Dabei ist  $u_k$  eine Zufallszahl im Bereich  $[0, 1)$ . Der Berechnung liegt eine Wahrscheinlichkeitsdichtefunktion zu Grunde (Gleichung 4.21), welche die Sucheigenschaften des Single-Point-Crossovers abbildet [44].

$$\mathcal{P}(\beta_k) = \begin{cases} 0.5(\eta_c + 1)\beta_k^{\eta_c}, & \text{wenn } \beta_k \leq 1 \\ 0.5(\eta_c + 1)\frac{1}{\beta_k^{\eta_c+2}}, & \text{sonst.} \end{cases} \quad (4.21)$$

Der Ausbreitungsfaktor  $\beta_k$  wird mit Gleichung 4.20 bestimmt, so dass die Fläche unter der Dichtefunktion  $\mathcal{P}(\beta_k)$  der Zufallszahl  $u_k$  entspricht. Mit den ermittelten  $\beta_k$  können die Abstände der Kinder zu den Eltern nach Gleichung 4.18 und 4.19 berechnet werden. Gemäß der Dichtefunktion werden die Kinder mit höherer Wahrscheinlichkeit nahe bei den Eltern liegen als weiter entfernt. Der Verteilungsindex<sup>6</sup>  $n_c$  ist eine nicht negative




Abbildung 4.9: Wahrscheinlichkeitsdichte für die Nachkommensbildung durch Rekombination bei unterschiedlichen  $n_c$ -Werten ([47])

reelle Zahl und hat einen maßgeblichen Einfluss auf die Verteilung der Nachkommen.

<sup>6</sup>distribution index

Abbildung 4.9 zeigt die Wahrscheinlichkeitsdichte für die Nachkommensbildung bei unterschiedlichen  $n_c$ -Werten. Je kleiner der Verteilungsindex, desto weiter liegen die Nachkommen von den Eltern entfernt. Ferner sind die Nachkommen symmetrisch zu den Eltern verteilt, wodurch eine Clusterbildung der Lösungen in Elternnähe vermieden wird.

Aus Gleichung 4.18 und 4.19 erhält man durch Subtraktion:

$$c_{2,k} - c_{1,k} = \beta_k (p_{2,k} - p_{1,k}) \quad (4.22)$$

Der Abstand der Nachkommen ist also proportional zu dem Abstand der Eltern. Liegen die Eltern weit auseinander, wie zu Beginn einer Optimierung, so haben auch die Nachkommen einen größeren Abstand zueinander (*exploration*). Mit zunehmender Konvergenz der Lösungen sinken durch Annäherung der Eltern auch die Abstände zwischen den Nachkommen, wodurch die Tiefensuche (*exploitation*) gefördert wird (vgl. Abschnitt 2.4.4). [46] beschreibt dieses Verhalten als eine selbst-adaptive Eigenschaft genetischer Algorithmen. Im vorliegenden Algorithmus wird eine Crossover-Wahrscheinlichkeit von  $p_c = 0.9$  analog zum Basiscode verwendet [175].

Im Gegensatz zum Crossover wird der Mutationsoperator deutlich weniger oft zur Nachkommensbildung eingesetzt (Wahrscheinlichkeit für Mutation  $p_m = 0.1$ ). Aus einem Elternindividuum  $p_k$  wird mithilfe des Störungsfaktors  $\delta_k$  ein Nachkomme  $c_k$  erzeugt (Gleichung 4.23). Dabei beschreiben  $p_{k,max}$  und  $p_{k,min}$  die obere bzw. untere Grenze des  $k$ -ten Parameters.

$$c_k = p_k + (p_{k,max} - p_{k,min}) \delta_k \quad (4.23)$$

Im NSGA-II wird bei der Mutation eine polynomialverteilte Wahrscheinlichkeitsdichte verwendet [48]:

$$\mathcal{P}(\delta_k) = 0.5 (\eta_m + 1) (1 - |\delta_k|)^{\eta_m} \quad (4.24)$$

Der Störungsfaktor  $\delta_k \in [-1, 1]$  wird ausgehend von einer Zufallszahl  $r_k \in [0, 1]$  berechnet zu:

$$\delta_k(r_k) = \begin{cases} (2r_k)^{\frac{1}{\eta_m+1}} - 1, & \text{wenn } r_k < 0.5 \\ 1 - (2(1 - r_k))^{\frac{1}{\eta_m+1}}, & \text{wenn } r_k \geq 0.5 \end{cases} \quad (4.25)$$

Ähnlich wie beim Crossover-Operator verwendet auch die Mutation einen Verteilungsindex  $\eta_m \geq 0$ , welcher die Form der Verteilung und damit den Eltern-Kind-Abstand beeinflusst (Abbildung 4.10). Je kleiner  $\eta_m$ , desto weiter entfernt liegt der Nachkomme

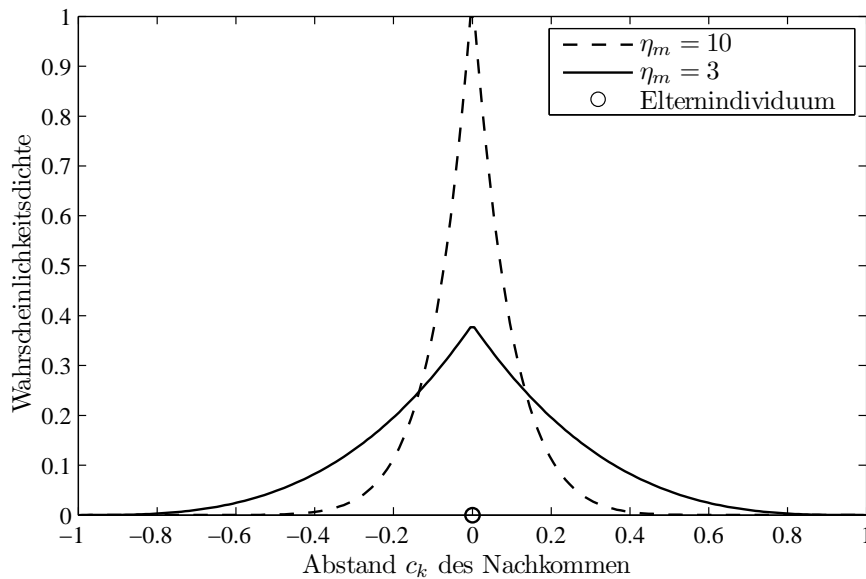


Abbildung 4.10: Wahrscheinlichkeitsdichte für die Nachkommensbildung durch Mutation bei unterschiedlichen  $n_m$ -Werten

durchschnittlich vom Elternindividuum. Die beiden Verteilungsindizes für Crossover und Mutation beeinflussen damit maßgeblich die Konvergenz des Algorithmus, da sie einen entscheidenden Einfluss auf die Diversität der Lösungen und damit auf die Breitensuche nehmen. In verschiedenen Veröffentlichungen wird ein adaptiver Verteilungsindex für Crossover bzw. Mutation als zusätzliche Erweiterung der Operatoren vorgeschlagen [31, 51].

Nach der Bestimmung der Zielfunktionswerte der neuen Lösungen wird jedem Individuum der kombinierten Population aus Eltern und Kindern eine Front sowie eine *crowding distance* zugewiesen. Im anschließenden Selektionsprozess (Replacement) werden die besten 50% der Individuen der kombinierten Population in die nächste Generation übernommen, wodurch Elitismus sichergestellt wird (Abbildung 4.11). Die neue Population wird mit den Individuen der einzelnen Fronten beginnend mit der niedrigsten nach und nach befüllt. Kann eine Front aufgrund der Populationsgröße nicht mehr vollständig aufgenommen werden, so werden die Individuen auf Basis ihrer *crowding distance* in absteigender Reihenfolge ausgewählt. Der Selektionsprozess zur Nachkommensbildung startet erneut sofern die Abbruchkriterien dies zulassen. Durch die Verwendung der *crowding distance* im Selektions- und Replacementprozess wird die Diversität der Lösungen erhöht.

Letztlich erhält man eine Menge an Kompromisslösungen aus denen ein oder mehrere Entscheidungsträger eine Lösung auswählen können. Mithilfe der approximierten Pareto-

#### 4 Methode zur Optimierung und Applikation der Betriebsstrategie

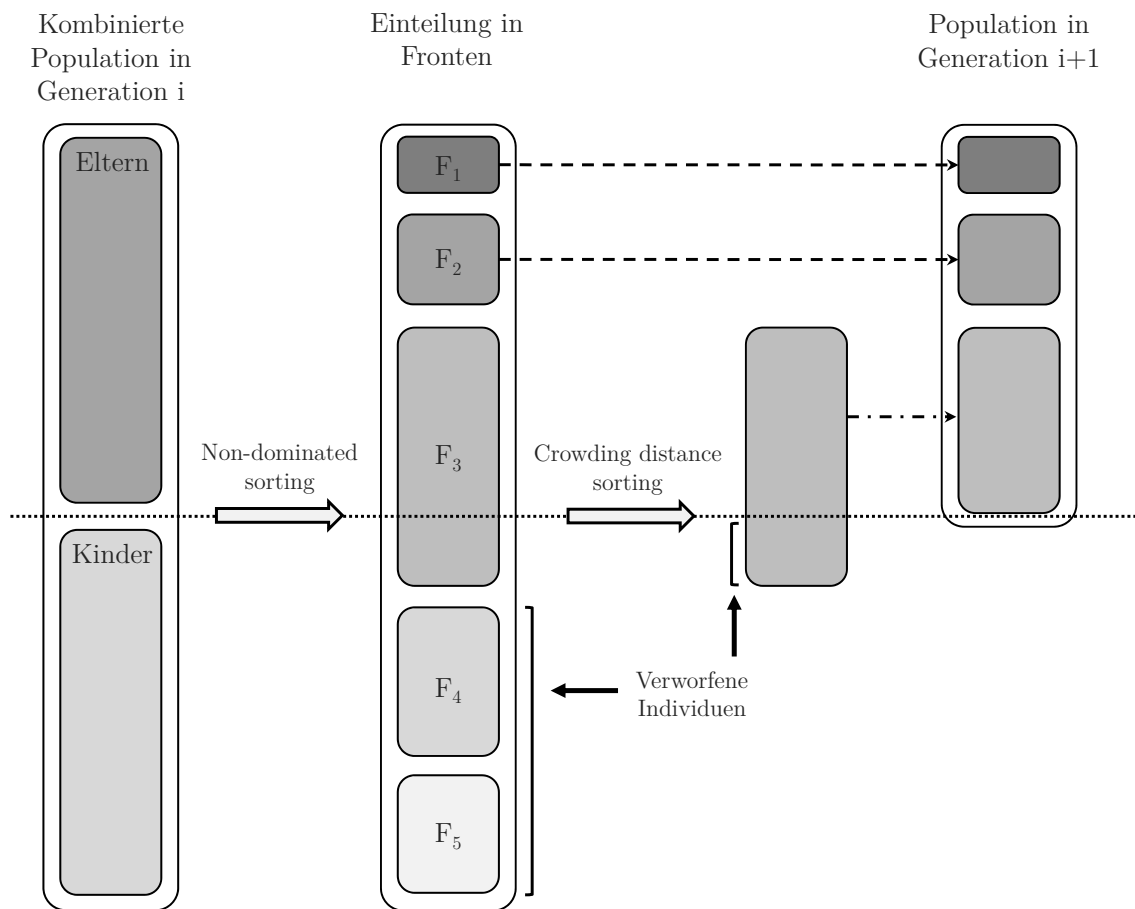


Abbildung 4.11: Auswahl der Individuen für die Folgegeneration [88, 50]

Front lässt sich der Zielkonflikt visualisieren. Zudem ist damit auch eine Quantifizierung der verschiedenen Lösungen gegeben. Bei der Auswahl einer Lösung spielen häufig übergeordnete Zielvorgaben oder auch bestimmte Präferenzen der Entscheidungsträger eine entscheidende Rolle. Die in dieser Arbeit verwendeten Zielkriterien für die Optimierung werden in Abschnitt 5.1 vorgestellt.



### 4.3.2 Anpassungen und Erweiterungen des Algorithmus

In dieser Arbeit wurde wie bereits erwähnt ein Open Source Matlab Code des NSGA-II verwendet [175]. Die nachfolgend aufgeführten Weiterentwicklungen des Algorithmus wurden im Wesentlichen zur Effizienzsteigerung des Optimierungsprozesses implementiert. Des Weiteren wurde eine grafische Benutzeroberfläche zur besseren Handhabung der Optimierungssteuerung geschaffen. Bei den Anpassungen sind zudem Erkenntnisse aus bereits bestehenden Arbeiten mit dem genannten NSGA-II-Matlab-Code eingeflossen [26, 77].

#### Diskretisierung und Berechnungshistorie

Die bei der Optimierung verwendeten Entscheidungsvariablen unterliegen im Steuergerätecode einer maximalen Genauigkeit, welche sich aus dem jeweiligen Datentyp und/oder technisch sinnvollen Wertebereichen ergibt. Der somit diskrete Parameterraum reduziert zum einen die Anzahl der möglichen Lösungen. Zum anderen wird eine eventuelle Abweichung von der optimalen Lösung (Pareto-Front) in Kauf genommen. Durch die Diskretisierung steigt auch die Wahrscheinlichkeit, dass Individuen mehrfach erzeugt und berechnet werden. Während [77] Duplikate durch den Vergleich mit in allen Generationen erzeugten Individuen eliminiert, werden im hier verwendeten Algorithmus lediglich Duplikate innerhalb einer Generation verworfen [88]. Dadurch erhalten auch bereits berechnete Individuen die Möglichkeit ihre Gene an die Nachkommen weiter zu vererben und dadurch neue Lösungspunkte zu generieren. Die Ergebnisse der bereits berechneten Lösungspunkte werden von einer Berechnungshistorie geliefert, so dass keine zusätzliche Simulation notwendig ist. Hierfür wird fortlaufend eine Historie der simulierten Parametersätze sowie zugehöriger Zielfunktionswerte erstellt.

Die Diskretisierung wurde adaptiv umgesetzt, d.h. das Diskretisierungsraster wird im Laufe der Optimierung nach und nach verfeinert [88]. Dafür wird ein Counter eingeführt, welcher die bereits verworfenen Individuen inkrementiert. Ab einen definierbaren Schwellwert wird die Diskretisierungsschrittweite halbiert. Die dynamische Diskretisierung ermöglicht zu Beginn der Optimierung eine verstärkte Breitensuche mit einem groben Raster und damit eine hohe Konvergenz. Die Verfeinerung der Diskretisierung fördert schließlich die Tiefensuche in der Umgebung der besten Lösungen. Die richtige Parametrierung der Verteilungsindizes  $\eta_c$  und  $\eta_m$  hat laut [26] einen ähnlichen Effekt wie eine adaptive Diskretisierung. Wie in Abschnitt 4.3.1 beschrieben, ist der Abstand zweier Nachkommen proportional zum Abstand der Eltern. Je größer die Verteilungsindizes,

desto näher liegen die Nachkommen bei den Eltern, da die Verteilungsdichtefunktionen sehr schmal verlaufen. Folglich konvergiert der Algorithmus nur sehr langsam da die Nachkommen häufiger in der Nähe der Eltern liegen. Bei der Verwendung kleinerer Indizes für Crossover und Mutation werden die Nachkommen weiter von den Eltern im Parameterraum platziert. Sie fördern demnach die Breitensuche zu Beginn (da großer Elternabstand auch großer Nachkommensabstand) und die Tiefensuche gegen Ende der Optimierung (da kleiner Elternabstand auch kleiner Nachkommensabstand).

#### **Adaptive Abbruchkriterien**

Zur Vermeidung von unnötigen Simulationsdurchläufen können neben einer vor Optimierungsstart festgelegten maximalen Anzahl zu berechnender Generationen zwei weitere Kriterien zum Beenden der Optimierung verwendet werden.

Im diskreten Parameterraum konvergiert der Algorithmus ab einer gewissen Anzahl an Generationen immer langsamer und die Lösungsgüte lässt sich nicht mehr signifikant steigern. Jeder Parameter hat wie bereits erwähnt eine technisch sinnvolle minimale Diskretisierungsschrittweite. Die Berechnung womöglich besserer Parameterkombinationen durch eine weitere Verfeinerung der Diskretisierung ist zwar möglich, wird jedoch als wenig sinnvoll und zudem zeitaufwändig erachtet. Im vorliegenden Algorithmus erhält jeder Parameter eine minimal zulässige Schrittweite für die Diskretisierung. Haben alle Entscheidungsvariablen ihre minimale Schrittweite erreicht, so wird die Optimierung nach der Folgegeneration beendet [88]. Das Kriterium hat sich insbesondere bei Optimierungsläufen mit langen Fahrprofilen als vorteilhaft in Bezug auf die Zeitersparnis erwiesen.

Weiterhin wird in [88] als Abbruchkriterium eine Auswertung der *crowding distance* vorgeschlagen. Es wird ein Maß für die Homogenität der Lösungsverteilung auf der nicht-dominierten ersten Front definiert. Das Kriterium greift z.B. dann, wenn bei noch nicht erreichter minimaler Parameterdiskretisierung bereits eine homogen verteilte Ergebnisfront im Zielfunktionsraum vorliegt und alle Individuen Teil dieser Front sind.

Die beiden Kriterien können unabhängig voneinander verwendet werden und sollen ein gutes Verhältnis von Lösungsgüte zu Optimierungsdauer ermöglichen. Durch die Kriterien beendete Optimierungsläufe können zu einem späteren Zeitpunkt mit schärferen Abbruchbedingungen nochmals aufgenommen werden um die Ergebnislösung ggf. zu erhöhen.

## SOC-Neutralität

Gemäß der ECE-Regelung 101 [189] ist bei der Typzulassung eines Hybridfahrzeugs innerhalb der europäischen Union eine negative SOC-Abweichung von 1% des Energieäquivalents des im Test verbrauchten Kraftstoffs zulässig. Kann die hier definierte Neutralität nicht erreicht werden, so ist eine Korrekturrechnung notwendig, wofür wiederum zusätzliche Tests zur Bestimmung eines Korrekturfaktors gefahren werden müssen. Eine positive Energiebilanz der Hochvoltbatterie muss hingegen nicht korrigiert werden. Auch für Fahrzeugzulassungen in den USA wird das 1%-tige Energieäquivalent als Bewertungskriterium herangezogen [157]. Je nach Fahrzyklus ergibt sich eine zugelassene SOC-Differenz beim hier betrachteten Hochvoltspeicher von  $\Delta SOC = \pm 4$  bis  $\pm 6\%$ . Die von den Behörden zugelassene SOC-Abweichung wird im Optimierungsprozess nicht berücksichtigt und soll im späteren Test lediglich als Sicherheitspuffer dienen. Eine Randbedingung bei der Auslegung der Betriebsstrategie in den jeweiligen Zyklen ist daher die Einhaltung der SOC-Neutralität. Auch für die Vergleichbarkeit der Ergebnisse wird ein SOC-neutraler Kraftstoffverbrauch gefordert.

Die SOC-Neutralität kann z.B. durch iterative Anpassung des Start-SOC erreicht werden. Eine exakte SOC-Neutralität erfordert in der Regel allerdings mehrere Simulationsdurchläufe pro Individuum, wodurch die Gesamtoptimierungszeit erheblich ansteigt. Daher wird eine maximale SOC-Differenz  $\Delta SOC_{max}$  definiert. Liegt die simulierte SOC-Differenz  $\Delta SOC = SOC_{end} - SOC_{start}$  betragsmäßig unter  $\Delta SOC_{max}$  wird der SOC-neutrale Gesamtkraftstoffverbrauch mithilfe eines Äquivalenzfaktors berechnet.

Der korrigierte Gesamtverbrauch  $B_{abs,ges}$  in  $l$  ergibt sich aus simulierten Absolutkraftstoffverbrauch  $B_{abs,sim}$  und der SOC-Differenz  $\Delta SOC$  in  $Wh$  zu:

$$B_{abs,ges} = B_{abs,sim} + k_{f,zyklus} \Delta SOC \quad (4.26)$$

Dabei beschreibt  $k_{f,zyklus}$  einen fahrzyklusabhängigen Korrekturfaktor mit der Einheit  $l/Wh$ . Dieser wurde simulativ für verschiedene Fahrprofile ermittelt und beträgt für den NEFZ  $k_{f,NEFZ} = 3,1 \cdot 10^{-4} l/Wh$  und den FTP-72  $k_{f,FTP-72} = 4,2 \cdot 10^{-4} l/Wh$  (vgl. [88]). Mit der Zyklusstreckenlänge  $s_{zyklus}$  lässt sich der Streckenverbrauch  $B_s$  in  $l/100km$  bestimmen:

$$B_s = \frac{B_{abs,ges}}{s_{zyklus}} 100 \quad (4.27)$$

Abbildung 4.12 zeigt den Zusammenhang zwischen Kraftstoffverbrauch und der SOC-Differenz  $\Delta SOC$  im NEFZ-Zyklus. Um den Nullpunkt ( $\Delta SOC = 0$ ) verhält sich der Kraftstoffverbrauch bis ca.  $\pm 100 Wh$  nahezu linear zum Energiedelta des

#### 4 Methode zur Optimierung und Applikation der Betriebsstrategie




Abbildung 4.12: Zusammenhang zwischen Kraftstoffverbrauch und  $\Delta SOC$  im NEFZ

Hochvoltspeichers. Der oben eingeführte Korrekturfaktor entspricht der Steigung der Näherungsgeraden im Zielfunktionsraum im Bereich  $\pm 50$  Wh. Für den FTP-72-Zyklus




Abbildung 4.13: Zusammenhang zwischen Kraftstoffverbrauch und  $\Delta SOC$  im FTP-72

ist der Zusammenhang in Abbildung 4.13 dargestellt. Hier ist ebenfalls die lineare Beziehung zwischen den Energieeinnahmen und -ausgaben des Hochvoltspeichers zum Kraftstoffverbrauch erkennbar.

Die Anwendung eines Korrekturfaktors ist zulässig, da die Leerlaufspannung<sup>7</sup> der verwendeten Speicherzellen im für die Optimierung relevanten SOC-Bereich nur eine sehr geringe Abhängigkeit vom SOC aufweist (Abbildung 4.14). Die Energieverluste

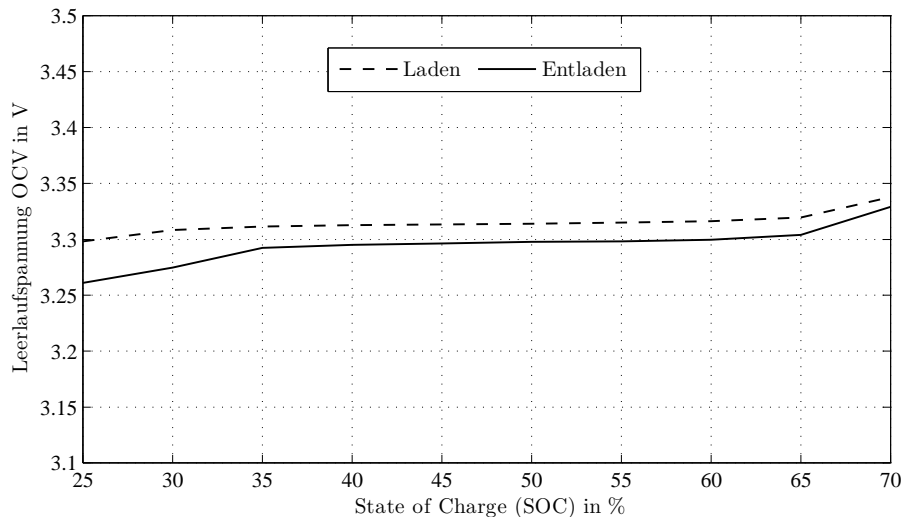


Abbildung 4.14: Abhängigkeit der Leerlaufspannung vom SOC beim Laden und Entladen

beim Laden/Entladen sind also nahezu unabhängig vom SOC. Anderenfalls könnte die Fitness der Individuen alleine durch den gewählten Start-SOC beeinflusst werden.

Bei den Optimierungsbeispielen in dieser Arbeit wird neben dem Kraftstoffverbrauch auch der elektrische Zeit- bzw. Streckenanteil als Zielgröße verwendet. Die Wahl von  $\Delta SOC_{max}$  hat dann einen entscheidenden Einfluss auf die Optimierungsergebnisse. Je größer der Korrekturbereich gewählt wird, desto stärker kann die korrigierte Lösung von der tatsächlich SOC-neutral simulierten Lösung abweichen (Abschnitt 5.1).

In Abbildung 4.15 ist der Ablaufplan zur Ermittlung des SOC-neutralen Kraftstoffverbrauchs dargestellt. Ausgehend von einem gewählten Start-SOC werden die Zielfunktionswerte eines Individuums bestimmt. Für  $|\Delta SOC| > \Delta SOC_{max}$  wird der End-SOC der aktuellen Simulation (i) zum Start-SOC der Folgesimulation (i+1) gewählt. Ist  $|\Delta SOC| \leq \Delta SOC_{max}$  wird mit dem Korrekturfaktor  $k_{f,zyklus}$  der Gesamtverbrauchs- wert berechnet und als Zielfunktionswert zurückgegeben (Gleichung 4.26). Bestimmte Parameterkombinationen können zum Alternieren der SOC-Differenz führen. In diesem Fall wird ein Bisektionsverfahren für die Ermittlung eines gültigen Start-SOC verwendet.

Eine zusätzliche Historie ermöglicht die Adaption der Start-SOC-Werte im Laufe der Optimierung. Hierfür werden alle simulierten Parameterkombinationen sowie deren

<sup>7</sup>OCV - Open circuit voltage

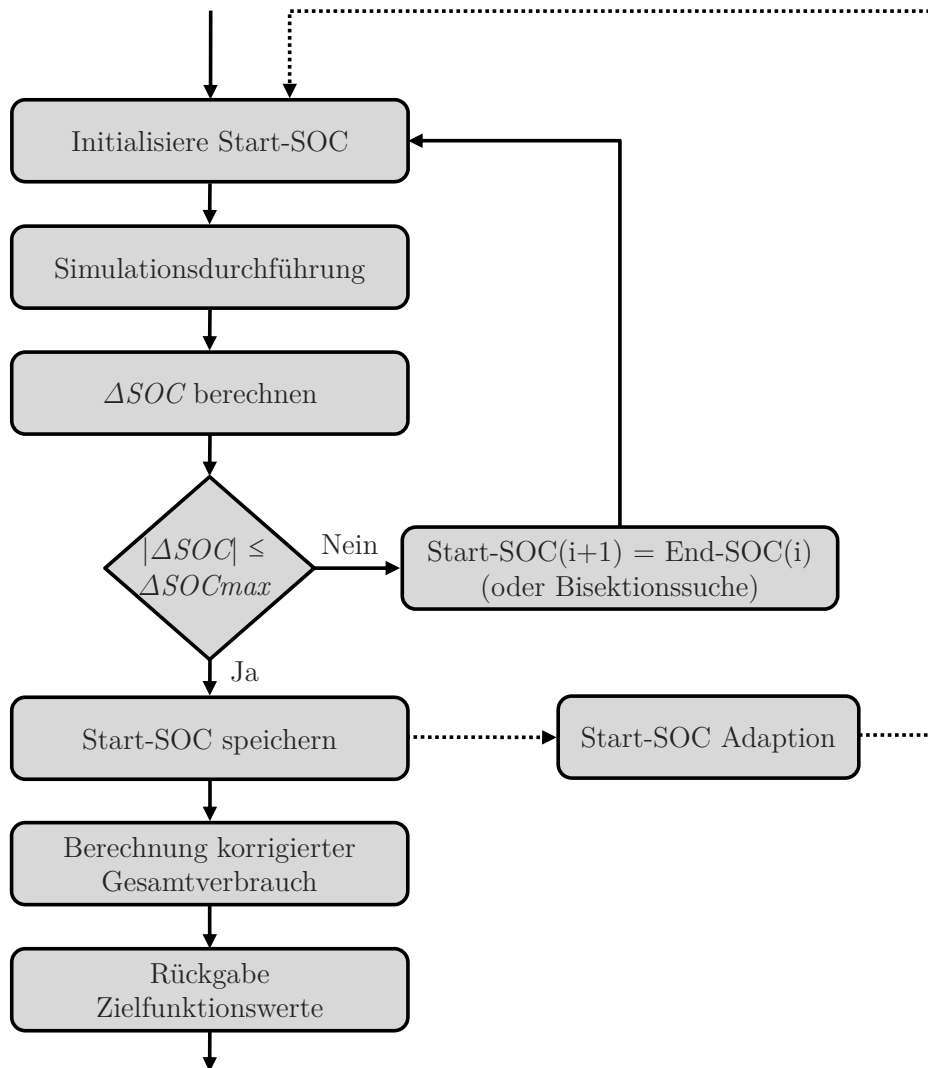


Abbildung 4.15: Umsetzung der SOC-Neutralität im NSGA-II-Algorithmus (vgl. [88])

Start-SOC-Werte gespeichert. Mit steigender Anzahl simulierter Lösungen kann die SOC-Neutralität durch geeignete Wahl des Start-SOC schneller hergestellt werden.

### Simulationsteuerung

Zur besseren Handhabung der Optimierung wurde eine grafische Benutzeroberfläche<sup>8</sup> geschaffen, welche als Schnittstelle zwischen Benutzer und Quellcode dient (vgl. [88]). Neben der Wahl der NSGA-II spezifischen Grundeinstellungen für den Optimierungslauf kann der Nutzer für jeden Parameter einen zulässigen Wertebereich sowie eine minimale

<sup>8</sup>Graphical User Interface (GUI)

Diskretisierungsschrittweite angeben (Abschnitt 5.1). Des Weiteren werden über die GUI auch mögliche Abbruchkriterien sowie die Forderung nach SOC-Neutralität aktiviert und konfiguriert ( $\Delta SOC_{max}$ ,  $k_{f,zyklus}$ ).

Sowohl begonnene als auch abgeschlossene Optimierungen können über die Oberfläche verwaltet werden. Die Optimierung wird nach jeder Generation samt vorgenommenen Einstellungen automatisch abgespeichert, wodurch bei einem Simulationsabbruch maximal eine Generation erneut berechnet werden muss. Unterbrochene Optimierungen können durch Laden der gesicherten Ergebnisdatei einfach wieder aufgenommen werden. Ferner ist auch ein Austausch zwischen verschiedenen Rechnern/Nutzern möglich, sofern das identische Simulationsmodell verwendet wird.

Die Visualisierung der Optimierungsläufe ist ebenfalls Bestandteil der GUI. Hierbei ist vor allem die Darstellung von Zielfunktions- und Parameterraum von großem Interesse. Zum einen kann der Fortschritt und die Konvergenz der Optimierung anhand verschiedener Plots des Zielfunktionsraums nachvollzogen werden. Verschiedene Schnittbilder des Parameterraums zeigen zum anderen mögliche Abhängigkeiten zwischen den Entscheidungsvariablen (Abschnitt 5.2).





# Kapitel 5

## Einsatz und Bewertung der Methode im Praxisbetrieb

In diesem Kapitel wird die im vorhergehenden Abschnitt vorgestellte Applikationsmethodik im realen Praxisbetrieb evaluiert. Aufgrund des breiten Anwendungsspektrums können lediglich einzelne ausgewählte Beispiele aufgeführt werden. Hierbei wird das Hauptaugenmerk auf die gesetzlichen Fahrzyklen NEFZ und FTP-72 gelegt, da diese im Fahrzeugentwicklungsprozess für die spätere Typzulassung sowie Kraftstoffverbrauchsangabe entscheidend sind. Schließlich spielt der angegebene Verbrauchswert auch beim Fahrzeugkauf eine entscheidende Rolle [122]. Weiterhin wird mit dem „MUC-Stadtzyklus“ ein kundennahes Fahrprofil untersucht.

### 5.1 Vorbetrachtungen und Problemformulierung

Ein wichtiger Bestandteil des Optimierungsprozesses ist die Formulierung der Optimierungsaufgabe nach Gleichung 2.3. Neben der Festlegung der Zielgrößen ist die Wahl der Entscheidungsvariablen und deren Wertebereich entscheidend.

Als wichtigste Zielgröße wird der Streckenverbrauch  $B_s$  definiert. Dieser lässt sich aus dem simulierten Absolutverbrauch  $B_{abs,sim}$  nach Gleichung 4.26 und 4.27 mithilfe des fahrzyklusabhängigen Korrekturfaktors bestimmen (Abschnitt 4.3.2). Als weitere Zielgröße wird in den folgenden Beispielen die elektrisch zurück gelegte Fahrstrecke  $s_{el}$  verwendet. Der elektrische Fahrbetrieb ist eine wichtige Ausprägung von Hybridfahrzeugen und zudem ein Verkaufsargument. Nach Abbildung 3.14 ist e-Fahren aus Lastpunktanhebung nur bis zu einer gewissen Leistungsgrenze effizienter als VM-Fahren. Die aus der Rekuperation gewonnene Energie kann aus Effizienzsicht hingegen immer vorteilhaft zum e-Fahren genutzt werden. Neben der e-Fahrstrecke dient auch der elek-

trische Zeitanteil  $t_{el}$ , d.h. die Zeit mit gestopptem Verbrennungsmotor, als Zielgröße. Im Vergleich zur elektrischen Wegstrecke  $s_{el}$  werden die Stillstandsphasen hier ebenfalls mit ausgewertet.

Die Art der Berücksichtigung der SOC-Neutralität über den Fahrzyklus hat einen signifikanten Einfluss auf die Optimierungszielgrößen  $s_{el}$  und  $t_{el}$ . Während der Streckenverbrauch auch bei großen SOC-Differenzen mithilfe des Korrekturfaktors hinreichend gut bestimmt werden kann, werden der elektrische Strecken- bzw. Zeitanteil erheblich verfälscht. So wird der Streckenverbrauch selbst bei einer großen negativen Energiebilanz sinnvoll korrigiert, die elektrische Fahrstrecke bleibt jedoch gleich. Simuliert man das genannte Szenario SOC-neutral, indem der Start-SOC um  $\Delta SOC$  niedriger gewählt wird, so verschieben sich durch das niedrigere SOC-Niveau elektrische und verbrennungsmotorische Fahranteile. Da für die Bestimmung der SOC-Neutralität mehrere Iterationen notwendig sind, welche die Rechenzeit erhöhen, und für bestimmte Parameterkombinationen nicht exakt bestimmt werden kann, wird zusätzlich der in Abschnitt 4.3.2 definierte SOC-Korrekturbereich  $\Delta SOC_{max}$  verwendet. Dieser wird allerdings sehr klein gewählt, um die Rückkopplung auf die genannten Zielgrößen minimal zu halten. Für die Optimierungsbeispiele wird  $\Delta SOC_{max} = \pm 0.35\% = \pm 5 \text{ Wh}$  gewählt (Abbildung 4.15).

Eine andere Möglichkeit ist die Definition der SOC-Neutralität  $\Delta SOC = 0$  als Nebenbedingung und die Berücksichtigung von Abweichungen durch einen Strafterm. Jedoch gestaltet sich laut [26] die Wahl eines passenden Straffaktors als schwierig. Ferner kann der elektrische Energieverbrauch über den Fahrzyklus in Form des  $\Delta SOC$  als zusätzliche Zielfunktion verwendet werden. Da entsprechend viele Individuen benötigt werden, um die sich ergebende Pareto-Fläche bei drei Zielfunktionen hinreichend zu besetzen, wird die Optimierungszeit erheblich verlängert.

Als vierte Zielgröße wird der akkumulierte Energiedurchsatz der Hochvoltbatterie als Maß für die Batteriebelastung vorgeschlagen ( $E_{bat,sum}$ ). Im hybriden Antriebsstrang ist der Traktionsspeicher im Hinblick auf die Lebensdauerstabilität von verfügbarer Leistung und nutzbarem Energieinhalt eine sensible Komponente. Neben der Speichertemperatur beeinflussen Entladetiefe und Energiedurchsatz maßgeblich die Lebensdauerstabilität (Abschnitt 3.1.4). Für weiterführende Lebensdaueruntersuchungen sollen mithilfe der Optimierungsmethode Betriebsstrategien identifiziert werden, welche optimal bezüglich Kraftstoffverbrauch und Batteriebelastung sind.

Wie in Abschnitt 2.4.4 bereits angeführt, steigt die empfohlene Populationsgröße mit der Dimension des Zielfunktionsraums exponentiell an, wodurch auch die Rechenzeit vervielfacht wird. Im dreidimensionalen Zielfunktionsraum muss der Anwender zudem

bereits aus einer Fläche die Kompromisslösung auswählen. Für Problemstellungen mit mehr als drei Dimensionen im Zielfunktionsraum erschwert sich sowohl die Visualisierung und Aufbereitung der Ergebnisse als auch die Wahl der Kompromisslösung deutlich. Im Rahmen dieser Arbeit wird daher mit lediglich zwei Zielfunktionen gearbeitet. Durch die SOC-neutrale Simulation in Verbindung mit einem schmalen Korrekturbereich konnte auf die Differenz von Start- und End-SOC als zusätzliches Zielkriterium verzichtet werden.

Die Anzahl der freien Variablen sowie deren Grenzen haben ebenfalls einen erheblichen Einfluss auf die Dauer und die Konvergenzgeschwindigkeit der Optimierung. Größere Populationen sind für die Konvergenz von Vorteil, jedoch erhöht sich damit wie schon erwähnt die Rechenzeit. Mit der Anzahl der Parameter wächst auch die Populationsgröße mit welcher der Suchraum hinreichend abgedeckt werden kann.

Für die Optimierungen dieser Arbeit wurden die wesentlichen Funktionen der Betriebsstrategie im Vorfeld identifiziert, so dass der Parameterraum auf drei Dimensionen begrenzt werden konnte. Abschnitt 3.3 stellte die Hauptstellhebel der Betriebsstrategie – die Ladezustandsregelung sowie die elektrische Fahrentscheidung – dar. Jede der Funktionen wird durch eine Vielzahl an Parametern beschrieben. Die Verwendung aller frei wählbaren Parameter als Entscheidungsvariablen für eine Optimierung ist nicht sinnvoll. Für die Ladezustandsregelung ist das maximale Aufwandsniveau des Optimalbereichs  $A_{opt}$  (Abbildung 3.11) die entscheidende Einflussgröße auf den Kraftstoffverbrauch, da es die LPAn-Leistung über einen Großteil des nutzbaren SOC-Bereichs definiert. Für die Überblendung der Lastpunktanhebung hin zum maximalen Laden bei niedrigem SOC bzw. zur Verhinderung einer Ladeleistung bei hohem SOC haben sich steile Gradienten als sinnvoll erwiesen [100].

Die elektrische Fahrentscheidung wird anhand des e-Fahrbereichs, welcher durch die e-Fahrkennlinie beschrieben wird, charakterisiert (Abbildung 3.15). Die e-Fahrkennlinie wird für den Optimierungslauf mithilfe eines Matlab-Skripts aus einer vorgegebenen mechanischen E-Maschinenleistung berechnet. Die e-Fahrentscheidung reduziert sich somit auf den Parameter  $P_{e-fahr}$ . Neben der Umrechnung der vorgegebenen Leistung in ein resultierendes Radmoment, abhängig von der Geschwindigkeit, werden noch zusätzliche Randbedingungen berücksichtigt:

- maximale e-Fahrgeschwindigkeit  $v_{max,el}$  als Systemgrenze<sup>1</sup>
- maximale Geschwindigkeit  $v_{max,ablegen}$  für Ablegen des Verbrennungsmotors bei

---

<sup>1</sup>Begrenzung auf Dauerleistung des elektrischen Systems zur Vermeidung eines zeitvarianten Verhaltens

negativem Radmoment aus Lebensdauerstabilitätsanforderung des SGR<sup>2</sup>

- maximales Radmoment für e-Fahren  $M_{rad,max}$  als Systemgrenze<sup>3</sup>
- minimales Radmoment für e-Fahren  $M_{rad,min}$  aus Fahrverhaltensbewertung<sup>4</sup>

Zur Vermeidung von häufigen Zustart- und Ablegevorgängen ist funktional bereits eine Hysterese in Form einer zweiten e-Fahrkennlinie integriert, welche um ein geschwindigkeitsabhängiges Radmomentenoffset unterhalb der eigentlichen Kennlinie liegt. Zum Ablegen des Verbrennungsmotors muss das vom Fahrer angeforderte Radmoment also unter beide Kennlinien fallen.

Ebenfalls signifikante Auswirkungen auf die Fahrzeugcharakteristik und das Energiemanagement hat die Mindestlaufzeit des Verbrennungsmotors  $T_{min,VM}$ , welche in Form eines Abschaltverhinderers (siehe Motor-Start-Stopp-Betriebsstrategie in Abschnitt 4.1.2) wirksam ist. Neben dem Kraftstoffverbrauch und der elektrischen Fahranteile beeinflusst die Mindestlaufzeit auch die Zustart- und Schalthäufigkeit und damit das Fahrverhalten.

Für die multikriterielle Optimierung ergibt sich folgender dreidimensionaler Parametervektor  $\mathbf{x}_{par}$ :

$$\mathbf{x}_{par} = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} = \begin{bmatrix} P_{e-fahr,max} \\ A_{opt} \\ T_{min,VM} \end{bmatrix} \quad (5.1)$$

Für die Entscheidungsvariablen wird neben einer maximalen Diskretisierungsschrittweite (Abschnitt 4.3.2) auch ein technisch sinnvoller Wertebereich vorgegeben (Tabelle 5.1).

Variable	Einheit	untere Grenze	obere Grenze	minimale Diskretisierung
$P_{e-fahr}$	kW	2	25	0.01
$A_{opt}$	g/kWh	190	350	0.1
$T_{min,VM}$	s	2	20	0.1

Tabelle 5.1: Variablengrenzen für die Betriebsstrategieoptimierung

Für die Optimierungsbeispiele in dieser Arbeit werden die vier beschriebenen Zielgrößen Streckenkraftstoffverbrauch  $B_s$ , elektrischer Streckenanteil  $s_{el}$ , elektrischer Zeitanteil

<sup>2</sup>Reduzierung der Zustartanzahl

<sup>3</sup>entspricht dem maximalen Moment der E-Maschine

<sup>4</sup>Reduzierung der Zustarthäufigkeit bei Konstantfahrten

$t_{el}$  und akkumulierter Energiedurchsatz der Hochvoltbatterie  $E_{bat,sum}$  verwendet. Der zweidimensionale Zielfunktionsvektor wird abhängig von der Problemstellung zusammengesetzt, wobei die Beispiele dieser Arbeit als erstes Zielkriterium immer den Streckenkraftstoffverbrauch nutzen. Die drei Optimierungsproblemstellungen, im Weiteren auch  $P1$ - $P3$  genannt, werden durch folgende Zielvektoren beschrieben (Gleichung 5.2 - 5.4):

$$\mathbf{f}_{1,ziel} = \begin{bmatrix} f_1 \\ f_2 \end{bmatrix} = \begin{bmatrix} B_s \\ -s_{el} \end{bmatrix} \quad (5.2)$$

$$\mathbf{f}_{2,ziel} = \begin{bmatrix} f_1 \\ f_2 \end{bmatrix} = \begin{bmatrix} B_s \\ -t_{el} \end{bmatrix} \quad (5.3)$$

$$\mathbf{f}_{3,ziel} = \begin{bmatrix} f_1 \\ f_2 \end{bmatrix} = \begin{bmatrix} B_s \\ E_{bat,sum} \end{bmatrix} \quad (5.4)$$

Die zusätzlichen Verbraucher im Hochvoltbordnetz, zusammengesetzt aus dem Leistungsbedarf des DC/DC-Wandlers für das Niedersvoltbordnetz sowie einer möglichen Leistungsanforderung des EKMV, werden für die Fahrzyklen entsprechend des real zu erwartenden Bedarfs vorgegeben. Für den MUC-Stadtzyklus wird zusätzlich mit einer Klimaanforderung von  $P_{EKMV} = 1000$  W gerechnet.

Die spezifischen Einstellparameter des verwendeten Algorithmus können im Vorfeld des Optimierungslaufs über die GUI festgelegt werden. Als Prozessor kommt ein Intel® Core™ i5-3320M mit zwei Kernen und einer Taktfrequenz von 2.6 GHz zum Einsatz. Für die aufgeführten Problemstellungen haben sich 70 Individuen als Populationsgröße als ausreichend erwiesen. Die Wahrscheinlichkeiten für Crossover  $p_c = 0.9$  und Mutation  $p_m = 0.1$  sowie die Teilnehmeranzahl von 2 bei der Turnierselektion wurden vom verwendeten Originalcode übernommen [175]. Die Verteilungsindizes für Crossover und Mutation werden im Vergleich zum übernommenen Quellcode ( $\eta_c = \eta_m = 20$ ) kleiner gewählt, um die Konvergenzgeschwindigkeit zu erhöhen (Abschnitt 4.3.1). Im Rahmen dieser Arbeit wurde mit  $\eta_c = \eta_m = 2$  gerechnet, was den Empfehlungen in anderen Veröffentlichungen nahe kommt [26, 44, 88].

Durch die Verwendung einer regelbasierten Betriebsstrategie kann keine global optimale Strategie garantiert werden, was allerdings auch nicht Ziel dieser Arbeit ist. Vielmehr ermöglicht die multikriterielle Parameteroptimierung der Betriebsstrategie eine gute Approximation des funktionalen Optimums. Dieses ist definiert als das mit

dem aktuellen Funktionsgerüst über Parametrierung erzielbaren Optimum. Mithilfe der Optimierungsergebnisse lassen sich funktionale Änderungen ableiten um näher an das globale Optimum zu kommen, falls dieses bekannt ist.

## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen

Bei der Optimierung der Betriebsstrategie in den gesetzlichen Zyklen wurde die Rückwärtssimulation (Open-Loop-Mode) verwendet. Dabei wird jeweils ein real gefahrenes Zyklusprofil vom Antriebsstrangprüfstand verwendet. Dies ermöglicht später eine Validierung der optimierten Parameter am realen System ohne Quereinflüsse durch Fahrer oder Umwelt. Die Ergebnisse können anschließend ins Fahrzeug übertragen werden. Die Methode kann nur zielführend eingesetzt werden, wenn Fahrzeug und Prüfstand ein annähernd gleiches Systemverhalten aufweisen. In Abschnitt 3.4 wurden die beiden Entwicklungsplattformen bereits diesbezüglich in einer Energieanalyse verglichen und bewertet.

### 5.2.1 Betriebsstrategieoptimierung im NEFZ

Ausgangspunkt für den Optimierungsprozess ist der Antriebsstrangprüfstand aus Abschnitt 3.2. Am Prüfstand wird ein NEFZ-Zyklus mit den aktuellen Programm- und Datenstand des Hybridsteuergeräts gefahren. Die Parametrierung der Ladezustandsregelung (Abschnitt 3.3.1) und der elektrischen Fahrentscheidung (Abschnitt 3.3.2) basiert im Wesentlichen auf Initialdaten, welche mithilfe von Simulationen (Closed-Loop-Mode) gewonnen wurden. Gerade in der frühen Entwicklungsphase, wenn die Fahrzeugversuchsträger für Rollenprüfstandsversuche noch nicht zur Verfügung stehen oder die Systemstabilität unzureichend ist, ermöglicht der Prüfstandsaufbau bereits erste Ergebnisse zum Kraftstoffverbrauch in den gesetzlichen Zyklen bzw. hinsichtlich des Systemverhaltens in definierten Fahrprofilen.

Im ersten Schritt werden die Messdaten in das Simulationsframework eingespeist, welches im Open-Loop-Mode verwendet wird (vgl. Abschnitt 4.1.1). Vor der eigentlichen Optimierung erfolgt ein Abgleich des rückwärts simulierten Fahrprofils mit den Messdaten. Mit dem gemessenen Summenradmoment  $M_{rad}$  kann durch Rückwärtssimulation der Leistungsfluss im Antriebsstrang simuliert werden. Dabei wird der am Prüfstand verwendete Programmcode, welcher die Betriebsstrategiefunktionen enthält, in Form der

## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen

Simulink-Modelle in das Simulationsframework eingebunden. Der Prüfstandsdatenstand wird anschließend eingelesen, so dass letztlich keine Programmcode- bzw. Datendifferenzen zwischen realem System und Simulation bestehen. Unterschiede zwischen Simulation und Messung können sich damit nur noch durch Ungenauigkeiten bei der Rückwärtsberechnung ergeben. Abbildung 5.1 stellt die wichtigsten simulierten und gemessenen Kennwerte gegenüber. Die Leistungsverläufe an Verbrennungsmotor und E-




Abbildung 5.1: Zeitverläufe im NEFZ von Antriebsprüfstandsmessung und Rückwärtssimulation

Maschine zeigen eine sehr gute Übereinstimmung. Die einzelnen Betriebsphasen e-Fahren, VM-Fahren, Lastpunktverschiebung, Rekuperation und Motor-Start-Stopp stimmen nahezu perfekt überein. Dies spiegelt sich auch im Ladezustand des Hochvoltspeichers

$SOC_{rel}$  wieder. Die maximale Abweichung zwischen Messung und Simulation beträgt lediglich  $\pm 10$  Wh. Die Modellierung des Zustrat- und Ablegeverhaltens ist von besonderer Bedeutung (Abschnitt 4.1.2). Auch hier sind keine signifikanten Differenzen im SOC-Verlauf erkennbar. Der berechnete Streckenverbrauch am Prüfstand auf Basis des gemessenen Absolutkraftstoffverbrauchs beträgt  $B_{s,pst} = 6.59$  l/100km. In der Simulation wurde unter Berücksichtigung der Katalysatorheizphase ein Streckenverbrauch von  $B_{s,sim} = 6.53$  l/100km erzielt.

Die verbrennungsmotorische Phase zu Testzyklusbeginn ist dem Katalysatorheizen geschuldet. Die Zeitdauer wird seitens der Emissionierung definiert und ist für die Betriebsstrategieoptimierung eine wichtige Randbedingung. Zusätzlich werden auch verbrennungsmotorische Schubphasen, welche von der On-Board-Diagnose (OBD) gefordert sind, berücksichtigt.

Abbildung 5.2 zeigt die Approximation der Pareto-Front im Zielfunktionsraum der ersten Problemstellung (Gleichung 5.2) nach 20 Generationen mit 70 Individuen (oben links) sowie die drei Projektionsflächen des dreidimensionalen Suchraums. Es ist zu erkennen, dass ein minimaler Kraftstoffverbrauch bei gleichzeitig maximaler e-Fahr-Strecke nur mit Grenzleistungen für e-Fahren im Bereich von ca. 6-9 kW erzielt werden kann. Die niedrigste und höchste e-Fahrleistung  $P_{e-fahr} = 6.33$  kW bzw.  $P_{e-fahr} = 8.96$  kW im Suchraum entspricht gleichzeitig dem niedrigsten bzw. höchsten Streckenverbrauch  $B_s$ . Größere Grenzleistungen als 8.96 kW verlängern die elektrische Fahrstrecke nicht mehr weiter während kleinere e-Fahrleistungen als 6.33 kW zu keiner Verbesserung des Kraftstoffverbrauchs führen. Mit steigender e-Fahrleistung wächst auch der Ladeaufwand  $A_{opt}$  stetig an. Da mehr Energie ausgegeben wird und sich gleichzeitig die VM-Laufzeit verkürzt muss die Energie mit erhöhtem Aufwand wieder geladen werden.

Zwischen minimalem und maximalem Verbrauchswert auf der Lösungsfront liegen lediglich 0.26 l/100km, während es bei dem Zielkriterium der elektrischen Strecke 1.96 km sind. Mit ca. 4 % Mehrverbrauch kann die e-Fahrstrecke um fast 46 % erhöht werden. Im Verlauf der dargestellten Front sind auch nach 20 Generationen Inhomogenitäten zu erkennen, welche auf den synthetischen Fahrzyklus zurückzuführen sind.

In Abbildung 5.3 sind die Ergebnisse der zweiten Problemformulierung  $P2$  (Gleichung 5.3) dargestellt. Der niedrigste Verbrauchswert ist, wie erwartet, identisch mit dem Ergebnis der ersten Problemstellung. Die inhomogene Besetzung der approximierten Pareto-Front ist auch in diesem Beispiel deutlich erkennbar. Mit ca. 4 % Mehrverbrauch lässt sich der absolute Zeitanteil ohne Verbrennungsmotor um 9.4 % erhöhen. Im Vergleich zur e-Fahrstrecke kann der elektrische Zeitanteil damit nur um ca. 14 % erhöht werden, was darauf schließen lässt, dass die Streckenunterschiede bei Problem



## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen

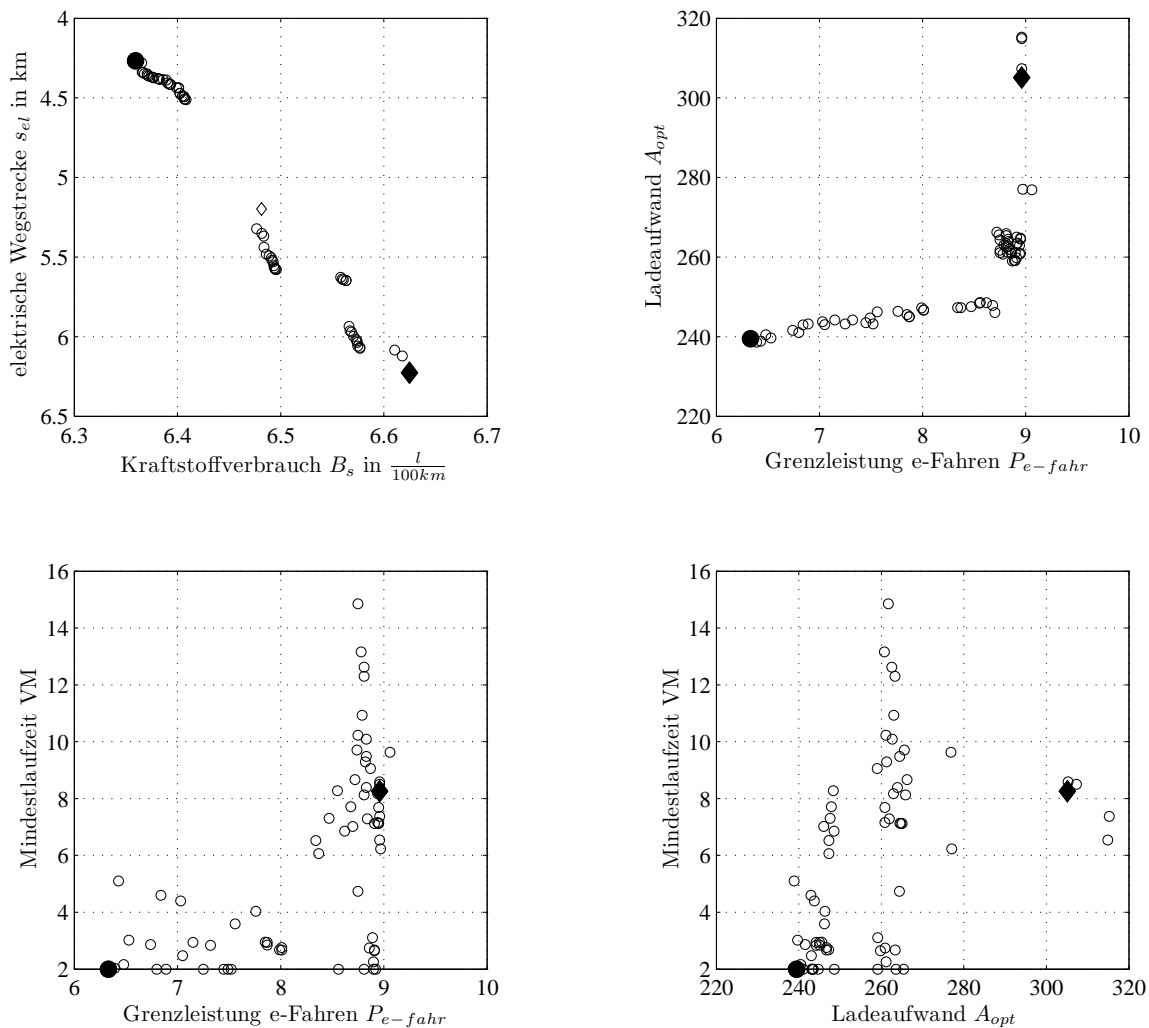


Abbildung 5.2: Optimierungsergebnisse von Problemstellung  $P1$  im NEFZ im Zielfunktions- und Variablenraum

$P1$  bei vergleichsweise hohen Geschwindigkeiten zu Stande gekommen sind. In den Schnittbildern des Parameterraums lassen sich ähnliche Zusammenhänge zwischen den Entscheidungsvariablen analog zum ersten Optimierungsproblem erkennen. Ferner sind zudem ähnliche Bereiche im Suchraum abgedeckt.

Die beiden Ergebnisse zeigen die starke Abhängigkeit von Kraftstoffverbrauch und der elektrischen Effizienzgrenze für e-Fahren. Ausgehend vom niedrigsten Streckenverbrauchswert kann die e-Fahrleistung zu Gunsten vom elektrischen Zeit- und Streckenanteil auf Kosten des Kraftstoffverbrauchs erhöht werden. Gemäß der Willans-Darstellung (Abbildung 3.3) liegt die e-Fahrleistung über der Effizienzgrenze für e-Fahren, d.h. die Gesamtwirkungsgradkette für e-Fahren aus Lastpunktanhebung ist schlechter als

## 5 Einsatz und Bewertung der Methode im Praxisbetrieb

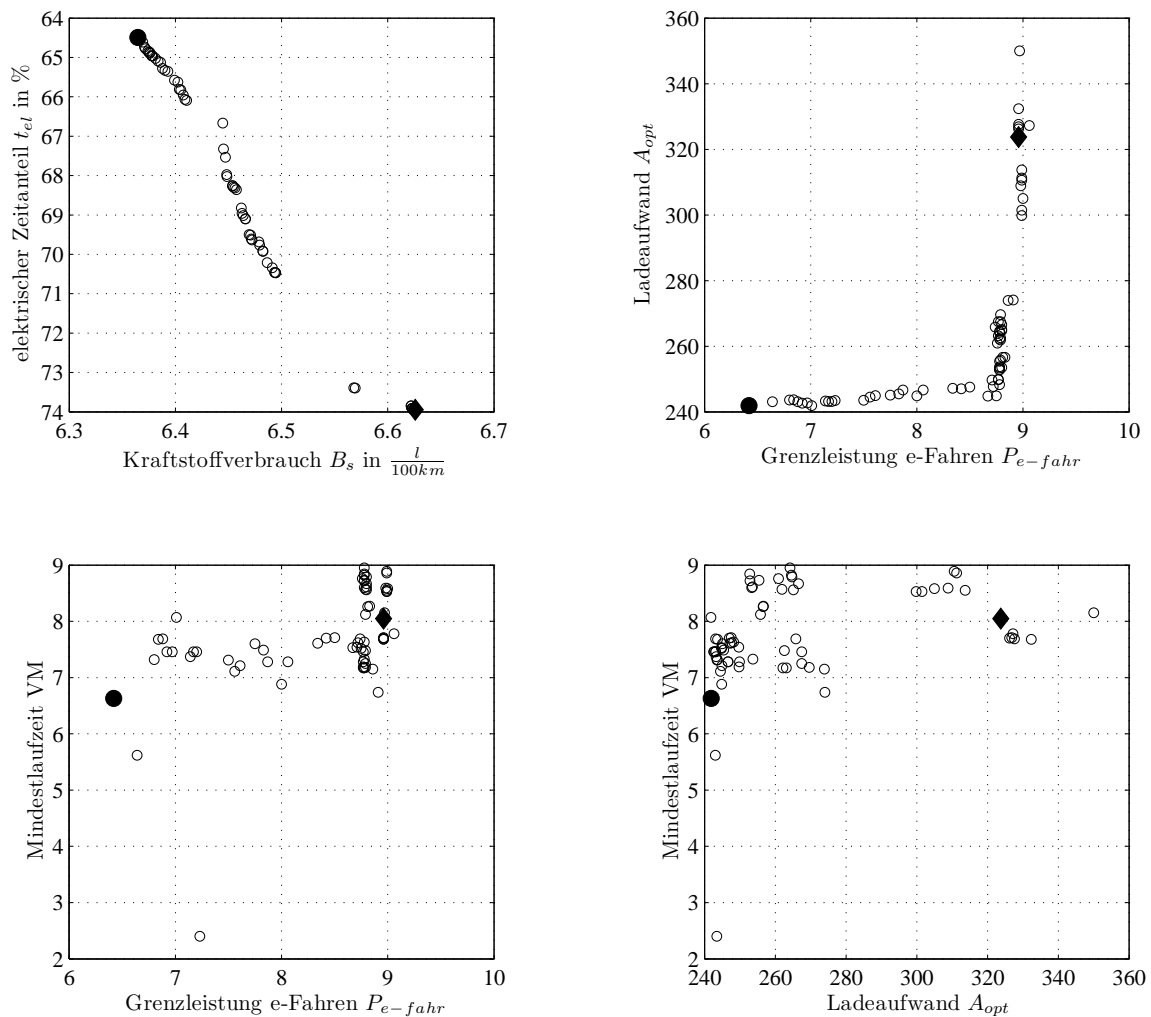


Abbildung 5.3: Optimierungsergebnisse von Problemstellung  $P2$  im NEFZ im Zielfunktions- und Variablenraum

reines VM-Fahren. Ab einer bestimmten Leistungsgrenze nehmen der besagte Zeit- und Streckenanteil sogar wieder ab, während der Streckenverbrauch weiter steigt. Durch die hohe Leistungsgrenze  $P_{e-fahr}$  verkürzen sich die VM-Phasen in denen durch Lastpunktanhebung geladen werden kann. Selbst mit maximalem Lademoment sinkt der SOC aufgrund der wenigen VM-Phasen bis zum Einschaltaufforderer ab. Als Folge läuft der Verbrennungsmotor auch in Fahrphasen, in denen e-Fahren effizienter wäre bzw. sogar im Fahrzeugstillstand, wo der Vorteil durch e-Fahren am größten ist. Dadurch verkürzen sich auch e-Fahrstrecke und -zeit während gleichzeitig der Verbrauch steigt. In Abbildung 5.4 sind als Bestätigung die elektrische Grenzleistung und der Kraftstoffverbrauch als Ergebnis einer zusätzlichen Optimierung im Zielfunktionsraum dargestellt.

Je größer  $P_{e-fahr}$  gewählt wird, desto größer ist auch der minimal mögliche Stre-

## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen




Abbildung 5.4: Approximierte Pareto-Front des Zielkonflikts minimaler Kraftstoffverbrauch und maximale e-Fahrleistung im NEFZ

ckenverbrauch  $B_s$ . Ab einer Grenzeleistung von ca. 13.5 kW verschlechtert sich der Kraftstoffverbrauch nur noch minimal bis zu der maximal freigegebenen Leistung von 25 kW, da das niedrige SOC-Niveau selbst durch maximale Lastpunktanhebung kaum noch verlassen werden kann und damit keine zusätzlichen e-Fahrphasen trotz größerer Grenzeleistungen anfallen. Eine Verdopplung der e-Fahrleistung von 6.5 kW auf 13 kW hat eine Verbrauchsmehrung von fast 10 % zur Folge.

Als dritte Problemstellung wurden die konträren Ziele minimaler Kraftstoffverbrauch und minimaler Energiedurchsatz der Hochvoltbatterie bewertet (Abbildung 5.5). Um den niedrigsten Verbrauch zu erzielen benötigt die Betriebsstrategie eine bestimmte Energiemenge für e-Fahren und folglich auch für die Lastpunktanhebung. Zusammen mit der anfallenden Rekuperationsenergie ergibt sich ein Gesamtenergiedurchsatz an der Hochvoltbatterie. Im betrachteten NEFZ-Zyklus sind ca. 1150 Wh zur Darstellung des besten Streckenverbrauchs notwendig. Entsprechend der vorangegangenen Ergebnisse liegt die elektrische Grenzeleistung für den besten Streckenverbrauch bei ca. 6.35 kW. Der Energiedurchsatz kann um über 70 % auf 325 Wh minimiert werden, wobei ein Verbrauchsnachteil von ca. 10 % in Kauf genommen werden muss. Der Lösungsvektor, welcher den niedrigsten Energiedurchsatz generiert, liegt in einem Eckpunkt des dreidimensionalen Suchraums. Alle drei Entscheidungsvariablen befinden sich folglich an einer ihrer in Tabelle 5.1 festgelegten Schranken. Als Grenzpotenzial für den minimalen

## 5 Einsatz und Bewertung der Methode im Praxisbetrieb

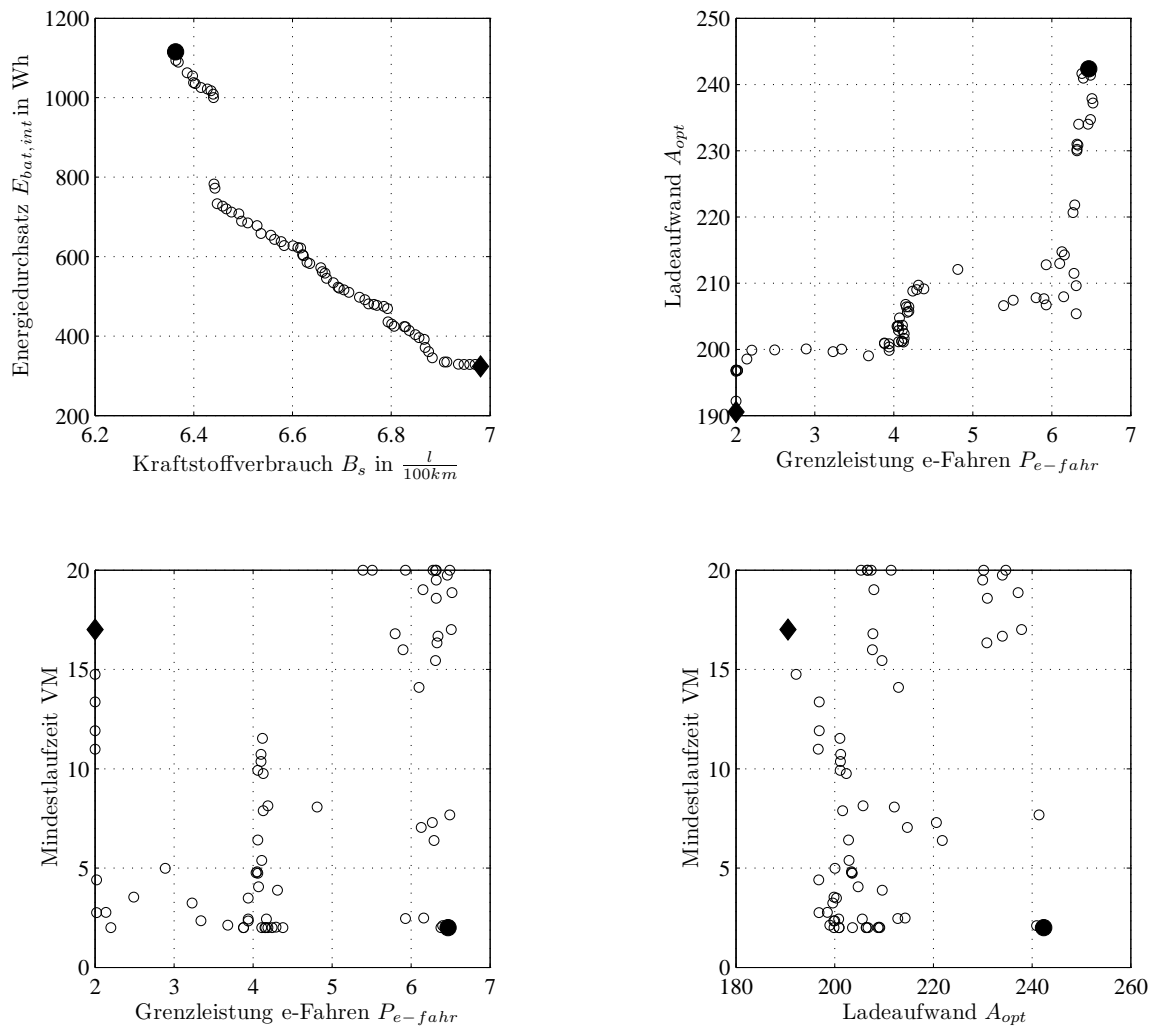


Abbildung 5.5: Optimierungsergebnisse von Problemstellung  $P3$  im NEFZ im Zielfunktions- und Variablenraum

Energiedurchsatz würde sich eine rein verbrennungsmotorische Fahrt ergeben, bei der das Bordnetz soweit wie möglich durch Energie aus Rekuperation abgedeckt wird.

Zur Validierung der Ergebnisse wurde ein Teil der ermittelten Parametersätze am Antriebsprüfstand gefahren. Abbildung 5.6 zeigt den Zielfunktionsraum der ersten Optimierung mit den Zielgrößen Kraftstoffverbrauch und e-Fahrstrecke zusätzlich mit dem am Antriebsprüfstand ermittelten Zielfunktionswerten. Die Versuche wurden analog zur Simulation SOC-neutral mit einem Korrekturbereich von  $\Delta SOC_{max} = \pm 0.35\% = \pm 5$  Wh durchgeführt. Die elektrische Wegstrecke wird anschließend mit einer Auswerterroutine berechnet. Der Kraftstoffverbrauch wird wie in Abschnitt 3.2 vorgestellt durch eine Messanlage bestimmt. Die in Abbildung 5.6 dargestellten Prüfstandswerte sind zu-

## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen




Abbildung 5.6: Zielfunktionsraum von Problemstellung  $P1$  im NEFZ mit verifizierten Lösungspunkten vom Antriebsprüfstand

dem jeweils aus drei Einzelmessungen gemittelt. Insgesamt liegen die am Prüfstand ermittelten Werte für e-Fahrstrecke und Kraftstoffverbrauch nahe an der approximierten Pareto-Front aus der Simulation. Beim Streckenverbrauch beträgt die maximale Abweichung 0.8 % vom simulierten Wert, bei der Wegstrecke  $s_{el}$  sind es maximal 0.55 %.

Jeder Simulationsaufruf benötigt abhängig von den betrachteten Fahrzyklen zwischen 7 s und 11 s bevor die Zielfunktionswerte an den Algorithmus zurück gegeben werden. Die eigentliche Berechnungszeit des Algorithmus macht folglich nur einen Bruchteil der Gesamtrechnenzeit aus. Da wie bereits erwähnt für eine SOC-neutrale Simulation mehrere Simulationsaufrufe notwendig sind, ergeben sich bei 20 Generationen mit 70 Individuen und im Mittel einer zusätzlichen Simulation für SOC-Neutralität ca. 2800 Aufrufe. Abhängig von der Start-SOC Adaption und der Berechnungshistorie liegt die Gesamtrechnenzeit zwischen 6 h und 10 h. Damit können in akzeptabler Zeit Optimierungsergebnisse erzielt werden.

In Abbildung 5.7 sind die Leistungen an Verbrennungsmotor und E-Maschine sowie die SOC-Verläufe für die beiden Optimalpunkte des ersten Optimierungsproblems, d.h. minimaler Streckenverbrauch und maximale e-Fahrstrecke, dargestellt. Die beiden SOC-Verläufe weisen im Stadtteil bis 800 s keine signifikanten Unterschiede auf. Die zusätzliche Energieausgabe in den elektrischen Beschleunigungsphasen für den Parametersatz „Max. e-Fahrstrecke“ wird durch ein deutlich stärkeres Ladement in der anschließenden

## 5 Einsatz und Bewertung der Methode im Praxisbetrieb

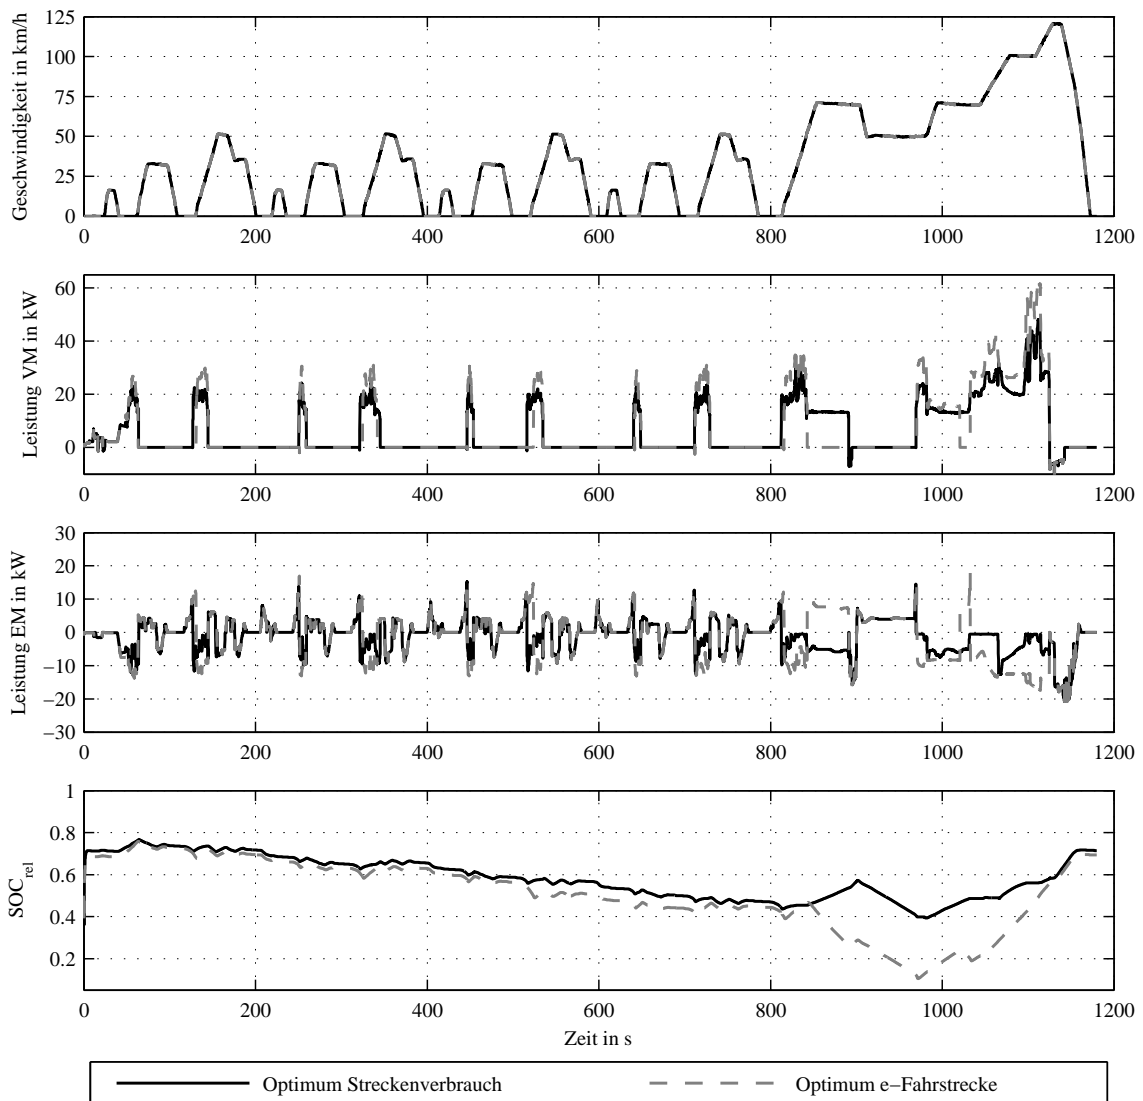


Abbildung 5.7: Simulierte Zeitverläufe im NEFZ der beiden Eckpunkte der approximierten Pareto-Front von Problemstellung  $P1$

VM-Phase immer wieder ausgeglichen. Im zweiten Zyklusabschnitt unterscheiden sich elektrische und verbrennungsmotorische Phasen in den  $70 \text{ km/h}$ -Konstantfahrten. Während mit dem Parametersatz „Min. Verbrauch“ die Geschwindigkeitsgrenze für e-Fahren bei ca.  $50 \text{ km/h}$  liegt, ermöglicht der Parametersatz „Max. e-Fahrstrecke“ e-Fahren bis über  $70 \text{ km/h}$ . Folglich unterscheiden sich die Leistungen und der SOC-Verlauf deutlich in diesem Zeitabschnitt. Die zusätzliche elektrische Strecke resultiert wie bereits analysiert in einem Verbrauchsnechtteil.

### 5.2.2 Betriebsstrategieoptimierung im FTP-72

Als weiterer gesetzlicher Zyklus wurde der FTP-72 betrachtet, welcher u.a. für die Fahrzeugzulassung auf dem US-amerikanischen Markt herangezogen wird. Dabei wird analog zum vorangegangenen Beispiel ein Prüfstandsprofildes FTP-72 mit dem Simulationsframework rückwärts berechnet. Wie in Abbildung 5.8 zu erkennen ist, weisen die




Abbildung 5.8: Zeitverläufe im FTP-72 von Antriebsprüfstandsmessung und Rückwärtssimulation

Leistungen an Verbrennungsmotor bzw. E-Maschine zwischen Messung und Simulation keine größeren Differenzen auf. Der simulierte SOC folgt dem gemessenen Wert mit einer maximalen Abweichung von 18 Wh. Anhand der geplotteten VM-Leistungen lässt sich

auch erkennen, dass die Zeitpunkte für Zustart und Ablegen des Verbrennungsmotors sehr gut übereinstimmen.

Der Verbrennungsmotor läuft zu Testbeginn bedingt durch die Beladungsgradermittlung des AKF ca. 115 s (Abschnitt 3.1). Weltweit existieren zulassungsrelevante Anforderungen hinsichtlich der HC-Emissionen. In den USA wird der Zulassungstest mit einem voll beladenen AKF gestartet, welcher für den nachfolgenden Verdunstungstest<sup>5</sup> gespült werden muss [190]. Zur Ermittlung des zu Testbeginn unbekanntem Beladungsgrads muss der Verbrennungsmotor daher eine definierte Zeit laufen, wodurch die Betriebsstrategie bezüglich e-Fahrens eingeschränkt wird. Dies ist eine wichtige Randbedingung für die spätere Optimierung, da in dieser Zeit ein Abschaltverhinderer das elektrische Fahren unterbindet. Zur vollständigen AKF-Regeneration kann abhängig von der gewählten Betriebsstrategie das e-Fahren auch temporär verhindert werden, um zusätzliche VM-Phasen zu erhalten.

Auf Basis der rückwärts simulierten Messung werden die in der Vorbetrachtung dargestellten Optimierungsprobleme untersucht. Die Abbildungen 5.9 und 5.10 zeigen die Ergebnisse im Zielfunktions- und Parameterraum für die ersten beiden Problemstellungen nach 20 Generationen mit jeweils 70 Individuen.

Die Lösungen sind bei beiden Beispielen deutlich homogener auf der approximierten Pareto-Front verteilt als beim NEFZ-Zyklus. Interessanterweise liegt die Effizienzgrenze für e-Fahren im verbrauchsgünstigsten Punkt mit  $P_{e-fahr} = 6.88 \text{ kW}$  trotz des wesentlich dynamischeren Fahrprofils nur unwesentlich höher als im NEFZ. Mit  $P_{e-fahr} = 9.49 \text{ kW}$  kann der größte elektrische Streckenanteil von 6.58 km erzielt werden und damit über 20 % mehr als mit dem verbrauchsgünstigsten Parametersatz. Der Verbrauchsnachteil beträgt in dem Fall lediglich 2.6 %. Gleiches Verhalten lässt sich auch für die elektrische Fahrzeit erkennen. Einer möglichen Mehrung der elektrischen Fahranteile um 11 % stehen weniger als 3 % Verbrauchsnachteil gegenüber.

Die Ergebnisse verdeutlichen sehr gut das Verhältnis zwischen Energieeinnahmen und Energieausgaben. Für einen optimalen Betrieb hinsichtlich Kraftstoffverbrauch und e-Fahrstrecke bzw. -zeit ist das Verhältnis von e-Fahren zur Lastpunktanhebung entscheidend. Eine Erhöhung der Leistung für e-Fahren gleicht bis zu einer bestimmten Grenze ein höherer Ladeaufwand aus. Kann selbst durch Ausschöpfung des maximalen Ladeleistungspotenzials die ausgegebene Energie nicht wieder eingenommen werden, führt dies zu einem deutlichen Mehrverbrauch. Die Energieausgaben bei Grenzleistungen  $P_{e-fahr} > 9.5 \text{ kW}$  können im betrachteten FTP-72-Zyklus nicht mehr durch

---

<sup>5</sup>SHED-Test - Sealed Housing Evaporative Determination Test



## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen

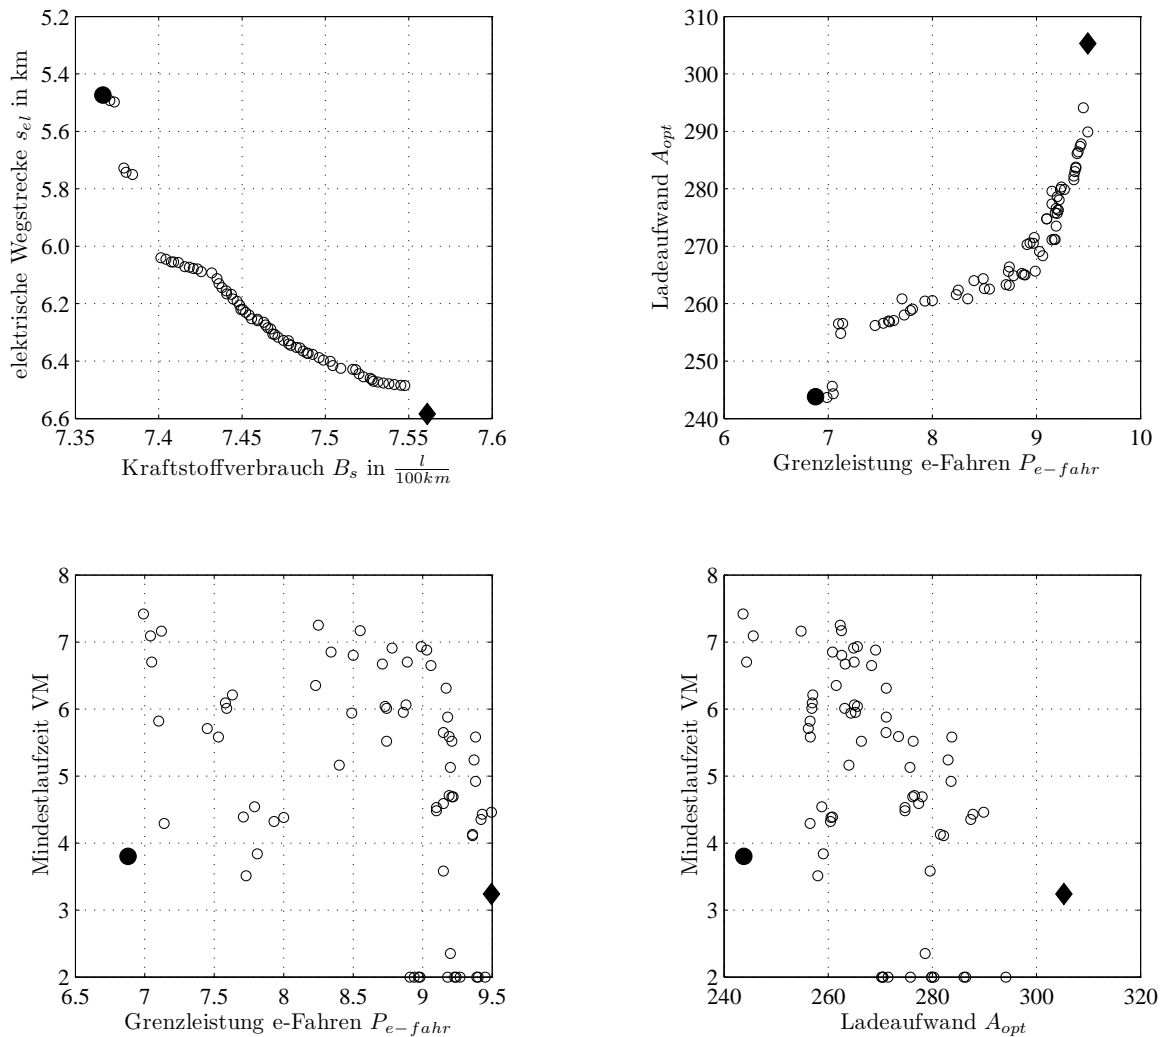


Abbildung 5.9: Optimierungsergebnisse von Problemstellung  $P1$  im FTP-72 im Zielfunktions- und Variablenraum

Lastpunktanhebung in den verfügbaren VM-Phasen kompensiert werden. Folglich entfallen mitunter auch energetisch effiziente elektrische Fahrphasen zum Zweck der Energiegenerierung durch Lastpunktanhebung. Das elektrische Fahrerlebnis wird maßgeblich durch die Kombination aus gewählter e-Fahrkennlinie und der Verfügbarkeit des elektrischen Systems bestimmt. Die Systemverfügbarkeit ist abhängig vom Ladezustand der Hochvoltbatterie, dem Ladepotenzial durch Lastpunktanhebung und Rekuperation, den Fahrwiderständen bzw. Fahrprofil sowie dem Fahrer. Zusätzlich beeinflusst im realen Fahrbetrieb auch die Temperatur der einzelnen Komponenten des elektrischen Systems die verfügbare elektrische Leistung.

## 5 Einsatz und Bewertung der Methode im Praxisbetrieb

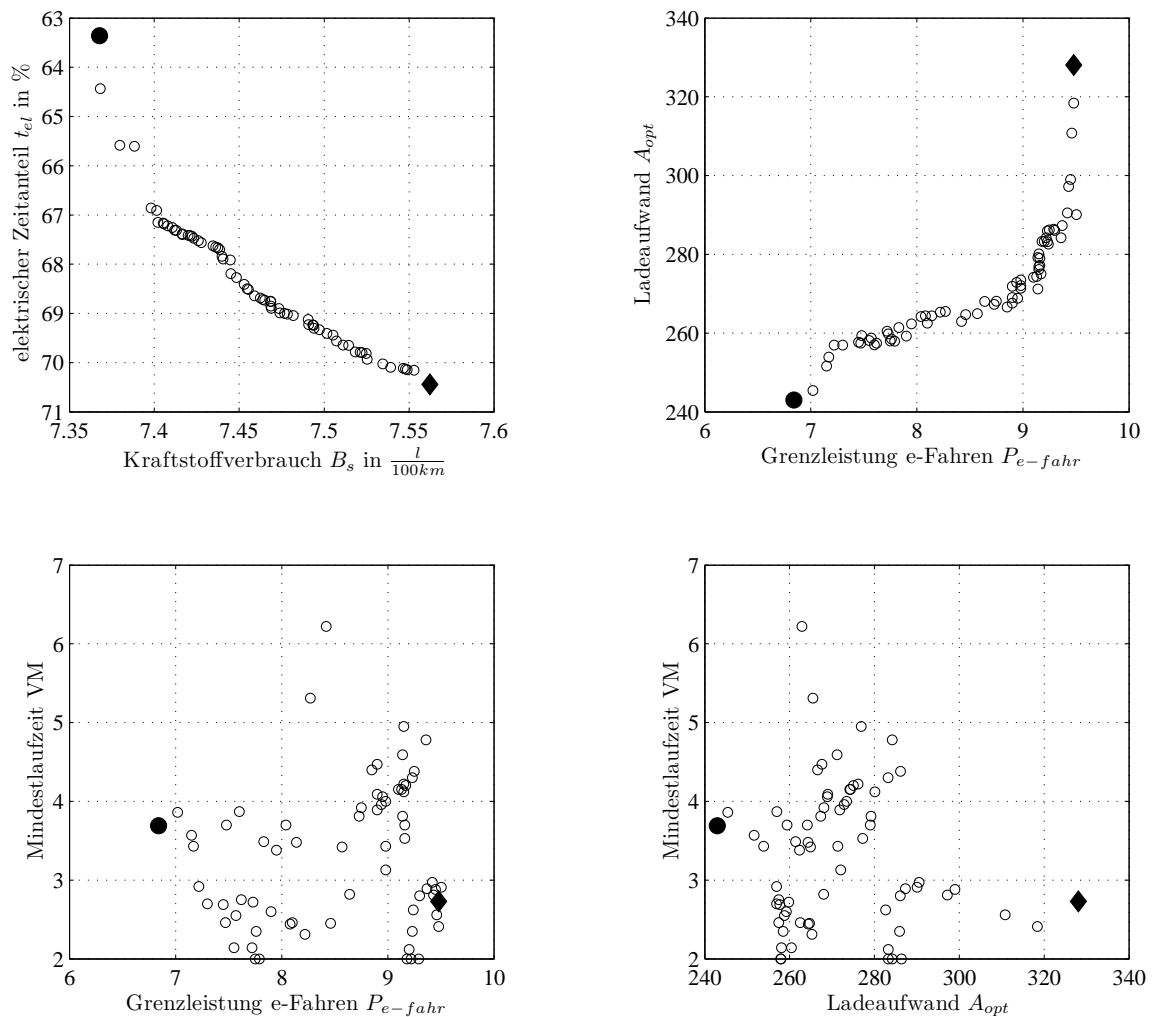


Abbildung 5.10: Optimierungsergebnisse von Problemstellung  $P2$  im FTP-72 im Zielfunktions- und Variablenraum

Die wichtigsten Ergebnisse der ersten beiden Optimierungsproblemstellungen sind in Tabelle 5.2 zusammengefasst. Der niedrigste ermittelte Kraftstoffverbrauchswert ist für beide Problemstellungen ca.  $7.36 \frac{l}{100km}$ . Entsprechend sind auch die korrespondierenden Parametersätze nahezu gleich. Die Individuen für maximale e-Fahrstrecke bzw. -zeit weisen ebenfalls nur geringe Unterschiede auf. Die beiden Zielkriterien stehen in keinem signifikanten Widerspruch zueinander, was sich auch im Verlauf der jeweiligen Pareto-Front im Zielfunktionsraum widerspiegelt. Die prozentuale Streuung zwischen minimalem und maximalem Zielfunktionswert der Pareto-Front fällt beim elektrischen Streckenanteil jedoch deutlich größer aus als beim Zeitanteil.

Abbildung 5.11 zeigt den Zielfunktionsraum für die Maximierung der e-Fahrleistung bei gleichzeitiger Minimierung des Kraftstoffverbrauchs im FTP-72. Darin lässt sich sehr

## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen

Problem	Kriterium	Zielfunktionen			Variablen		
		$B_s$ l/100 km	$s_{el}$ km	$t_{el}$ s	$P_{e-fahr}$ kW	$A_{opt}$ g/kWh	$T_{min,VM}$ s
P1	Verbrauch	7.367	5.47	-	6.88	243.8	3.8
P1	Strecke	7.561	6.58	-	9.49	305.3	3.2
P2	Verbrauch	7.368	-	63.4	6.84	243.0	3.7
P2	Zeit	7.562	-	70.4	9.48	328.1	2.7

Tabelle 5.2: Ergebnisübersicht der Optimierungsprobleme  $P1$  und  $P2$  im FTP-72

gut ein annähernd linearer Zusammenhang zwischen den beiden Kriterien erkennen. Mit steigender elektrischer Grenzleistung erhöht sich auch der minimal erzielbare Streckenverbrauch. Für Leistungen  $> 20$  kW wird der Verbrauch nur noch minimal schlechter, da die zusätzlich freigegebene Antriebsleistung durch das dauerhaft niedrige SOC-Niveau kaum abgerufen werden kann. Der Sachverhalt ist in Abbildung 5.12 veranschaulicht. Hier werden die Leistungsverläufe von minimaler und maximaler elektrischer Grenzleistung des Zielfunktionsraums aus Abbildung 5.11 gegenübergestellt. Die minimale Grenzleistung entspricht dabei dem minimalen Streckenverbrauch. Wie bereits beschrie-




Abbildung 5.11: Approximierte Pareto-Front des Zielkonflikts minimaler Kraftstoffverbrauch und maximale e-Fahrleistung im FTP-72

## 5 Einsatz und Bewertung der Methode im Praxisbetrieb




Abbildung 5.12: Simulierte Zeitverläufe im FTP-72 der beiden Eckpunkte der approximierten Pareto-Front in Abbildung 5.12

ben kann für groß gewählte  $P_{e-fahr}$  die Energie nicht im selben Maße generiert werden wie sie durch e-Fahren ausgegeben wird. Daraus resultieren ein dauerhaft niedriges SOC-Niveau sowie ein Verbrauchsnachteil, welcher sich im Beispiel auf ca. 13% beläuft. Die e-Fahrphasen werden für den Parametersatz „Pefahr-MAX“ hauptsächlich durch den SOC bestimmt (Einschaltaufforderer und Abschaltverhinderer) und nur noch selten durch die e-Fahrkennlinie. Der Fahrer kann zwar elektrische Antriebsleistungen von bis zu 25 kW erleben, allerdings ist das Verhalten stark zeitvariant. Zusätzlich sind elektrische Antriebsleistungen über 9.5 kW wie bereits erwähnt mit einem Verbrauchsnachteil verbunden.

## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen

Abbildung 5.13 zeigt die Leistungs- und SOC-Verläufe im FTP-72 der beiden optimalen Parametersätze aus Problemstellung *P1*. Obwohl sich die Grenzleistungen für




Abbildung 5.13: Simulierte Zeitverläufe im FTP-72 der beiden Eckpunkte der approximierten Pareto-Front von Problemstellung *P1*

e-Fahren zwischen beiden Simulationen nur um etwas mehr als 2.6 kW unterscheiden, ist das SOC-Niveau deutlich verschieden. Die Differenz im Streckenverbrauch beträgt ca. 2.6 %, bei der elektrischen Fahrstrecke sind es ca. 20 %. Die Betriebsphasen unterscheiden sich im Vergleich zum vorangegangenen Beispiel weniger stark. Ein Großteil der zusätzlichen elektrischen Energieausgaben für den Parametersatz „Optimum e-Fahrstrecke“ wird in den Beschleunigungsphasen durch ein späteres Auslösen des VM-Zustarts ausgegeben und muss entsprechend in den VM-Phasen nachgeladen werden.

An dieser Stelle soll kurz auf den Einfluss der elektrischen Verbraucher, welche durch das 12 V-Bordnetz und einer zusätzlichen Klimaanlage definiert sind, eingegangen werden. Da diese als Energieausgaben anzurechnen sind, lässt sich mithilfe des Willans-Ansatzes zeigen, dass ein steigender Bordnetzbedarf in etwa gleichem Maße die Effizienzgrenze für e-Fahren mindert. Weiterhin erhöht sich natürlich der Streckenverbrauch äquivalent mit der Bordnetzlast, da die Energie nicht mehr für den Antrieb zur Verfügung steht, aber durch Lastpunktanhebung erzeugt werden muss. Davon ausgehend lässt sich z.B. ein bordnetzabhängiger Zusatzladeaufwand definieren, welcher das Aufwandsniveau des Optimalbereichs anhebt um die zusätzlichen Energieausgaben zu kompensieren. Eine gleichzeitige Adaption der e-Fahrkennlinie wäre ebenfalls denkbar, wird aber aufgrund der daraus resultierenden Verstärkung des zeitvarianten Verhaltens als wenig sinnvoll erachtet.

Abbildung 5.14 zeigt den Zielfunktionsraum von Problemstellung  $P1$  zusätzlich mit verifizierten Lösungspunkten vom Antriebsprüfstand. Die ermittelten Zielwerte der




Abbildung 5.14: Zielfunktionsraum von Problemstellung  $P1$  im FTP-72 mit verifizierten Lösungspunkten vom Antriebsprüfstand

Prüfstandsmessungen repräsentieren dabei sehr gut die approximierte Pareto-Front aus der Simulation. Die prozentuale Abweichung beim Streckenverbrauch liegt mit maximal 0.95 % über der Abweichung für den NEFZ-Zyklus, was auch hier auf das wesentlich dynamischere Profil zurückzuführen ist. Bei der e-Fahrstrecke beträgt die Abweichung zur Simulation maximal 0.6 %.

## 5.2 Auslegung der Betriebsstrategie in den gesetzlichen Emissionszyklen

Die Optimierungsergebnisse für Problemstellung  $P3$  im FTP-72 sind in Abbildung 5.15 zusammengefasst. Ähnlich wie schon beim NEFZ kann der Energiedurchsatz der

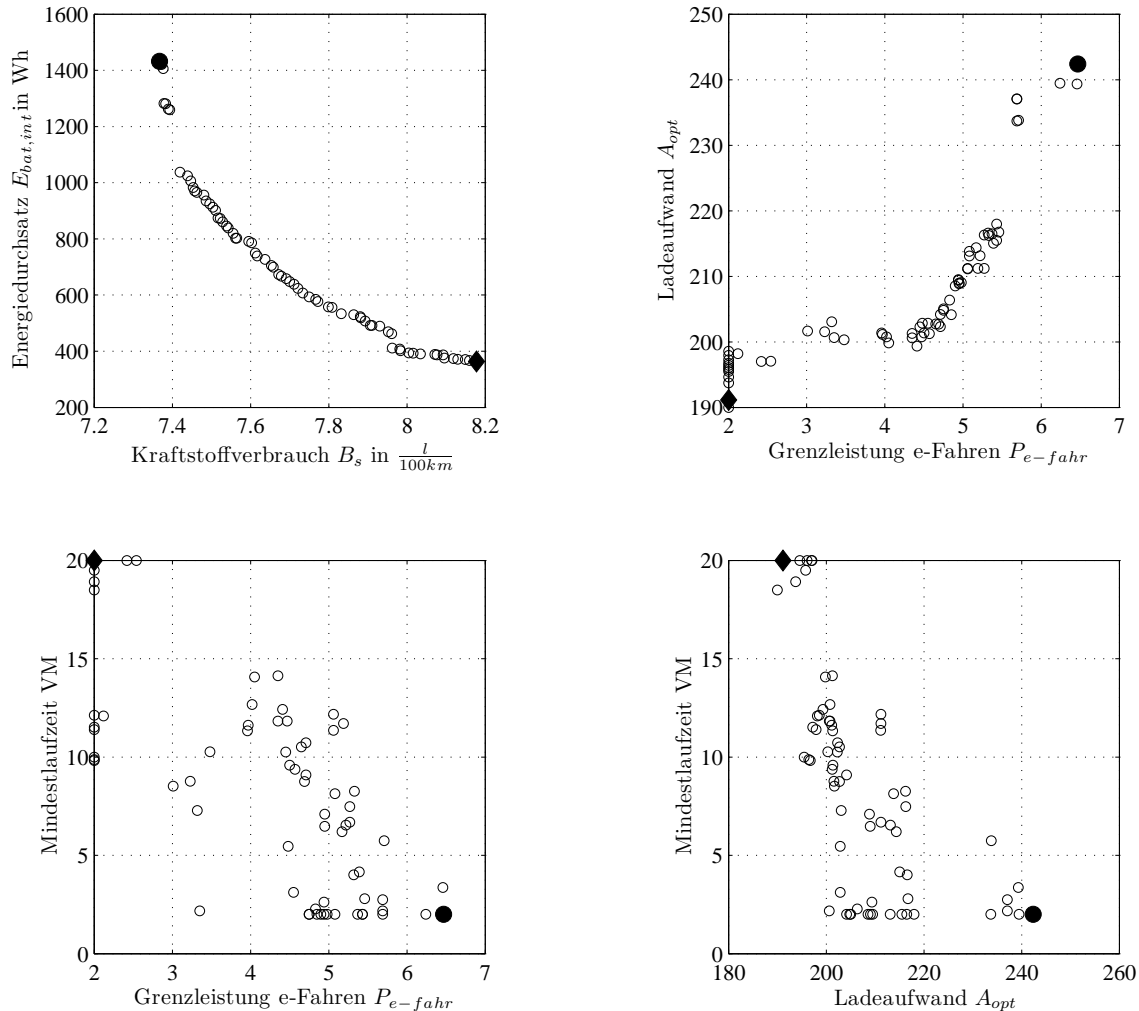


Abbildung 5.15: Optimierungsergebnisse von Problemstellung  $P3$  im FTP-72 im Zielfunktions- und Variablenraum

Batterie innerhalb der zugelassenen Parametergrenzen um fast 75% reduziert werden. Der Streckenverbrauch würde sich gleichzeitig um über 12% auf  $8.18 \text{ l}/100 \text{ km}$  erhöhen. Die Schnittbilder des Parameterraums verdeutlichen, dass die elektrische Grenzleistung sowie der Ladeaufwand den Energiedurchsatz maßgeblich bestimmen. Im Zielfunktionsraum lässt sich sehr gut der Trade-Off zwischen dem Energiedurchsatz sowie dem Kraftstoffverbrauch erkennen und ermöglicht z.B. die Auswahl einer Kompromisslösung hinsichtlich der Lebensdauerfestigkeit des Hochvoltspeichers.

### 5.3 Betriebsstrategieoptimierung im Kundenzyklus

Neben der Auslegung der Betriebsstrategie in den gesetzlichen Zyklen wurden auch reale Fahrprofile für die Optimierung herangezogen. Das Geschwindigkeitsprofil „MUC-Stadtzyklus“ wurde mit einem Versuchsträger im Stadtgebiet München aufgenommen und wird für die Rückwärtssimulation in das Framework eingebunden. Der gemessene Bordnetzbedarf dient ebenfalls als Eingangsgröße für die Simulation. Im fast 45 min dauernden Zyklus werden 22 km bei einer maximalen Geschwindigkeit von 69 km/h zurückgelegt.

Abbildung 5.16 zeigt den Zielfunktions- und Suchraum nach 20 Generationen mit 70 Individuen für Problemstellung P1. Die elektrischen Grenzleistungen, die ein Optimum

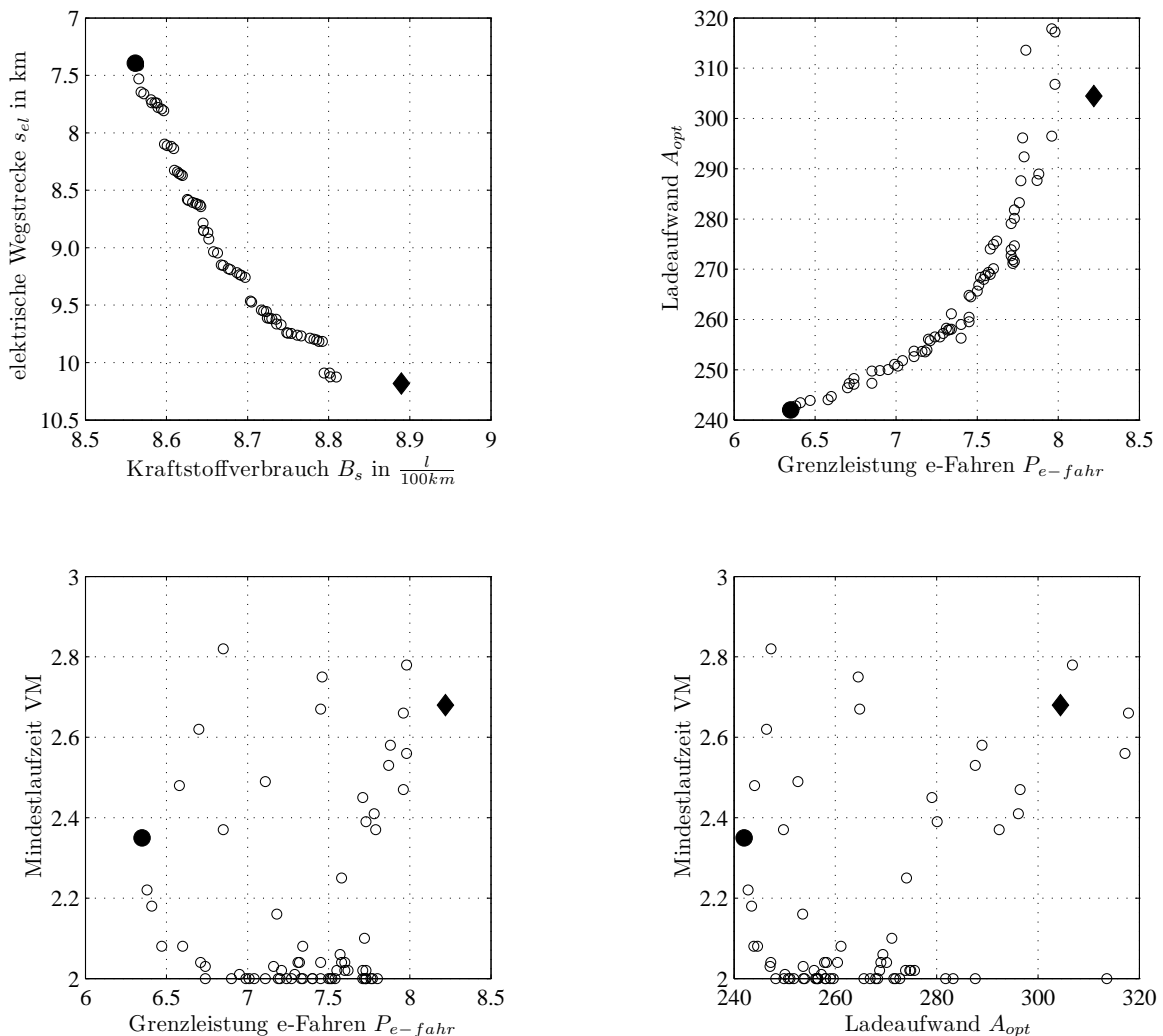


Abbildung 5.16: Optimierungsergebnisse von Problemstellung P1 im MUC-Stadtzyklus im Zielfunktions- und Variablenraum



im Bezug auf Kraftstoffverbrauch und e-Fahrstrecke bilden, liegen dabei in einem ähnlichen Bereich wie bei den bereits untersuchten gesetzlichen Zyklen. Im Parameterraum lässt sich ebenfalls gut die bereits bekannte Korrelation von Ladeaufwand und Grenzleistung erkennen. Die elektrische Fahrstrecke kann im Vergleich zum verbrauchsoptimalen Punkt um über 37% gesteigert werden. Dafür müssen in dem Fall weniger als 4% Verbrauchsnachteile in Kauf genommen werden. Der beste Verbrauch wird mit einer e-Fahrleistung von lediglich 6.35 kW und einem Ladeaufwand von 241.9 g/kWh erzielt. Die Mindestlaufzeit des Verbrennungsmotors beträgt in dem Fall nur 2.35 s. Die kurze Laufzeit muss im realen Fahrversuch hinsichtlich Fahrverhalten und Komfort bewertet werden.

In Abbildung 5.17 ist die approximierte Pareto-Front des Zielkonflikts minimaler Kraftstoffverbrauch und maximale e-Fahrleistung dargestellt. Zwischen 7 kW und 12 kW




Abbildung 5.17: Approximierte Pareto-Front des Zielkonflikts minimaler Kraftstoffverbrauch und maximale e-Fahrleistung im MUC-Stadtzyklus

steigt der minimal erzielbare Kraftstoff um fast 10% an. Für 25 kW e-Fahrleistung liegt die Verbrauchsmehrung bei 14%. Der minimale Streckenverbrauch liegt mit 8.56 l/100 km über den minimalen Verbrauchswerten der gesetzlichen Zyklen, was zum einen dem Fahrprofil und zum anderen der erhöhten Bordnetzlast durch Vorgabe einer Klimaanlage geschuldet ist. Die Mindestlaufzeit des Verbrennungsmotors ist für alle Lösungen der Pareto-Front kleiner als 3 s, was sich auf das dynamische Fahrprofil zurückführen lässt. Die Grenzleistung  $P_{e-fahr}$  sowie der Ladeaufwand  $A_{opt}$  unterscheiden sich nur

## 5 Einsatz und Bewertung der Methode im Praxisbetrieb

unwesentlich zum verbrauchsoptimalen Lösungspunkt im FTP-72. Lediglich die Mindestlaufzeit des Verbrennungsmotors  $T_{min,VM}$  weist eine etwas größere Abweichung verglichen mit dem NEFZ- und FTP-72-Wert auf.

In Abbildung 5.18 sind die Leistungs- und SOC-Verläufe im MUC-Stadtzyklus der beiden optimalen Parametersätze aus Problemstellung  $P1$  visualisiert. Wie schon in

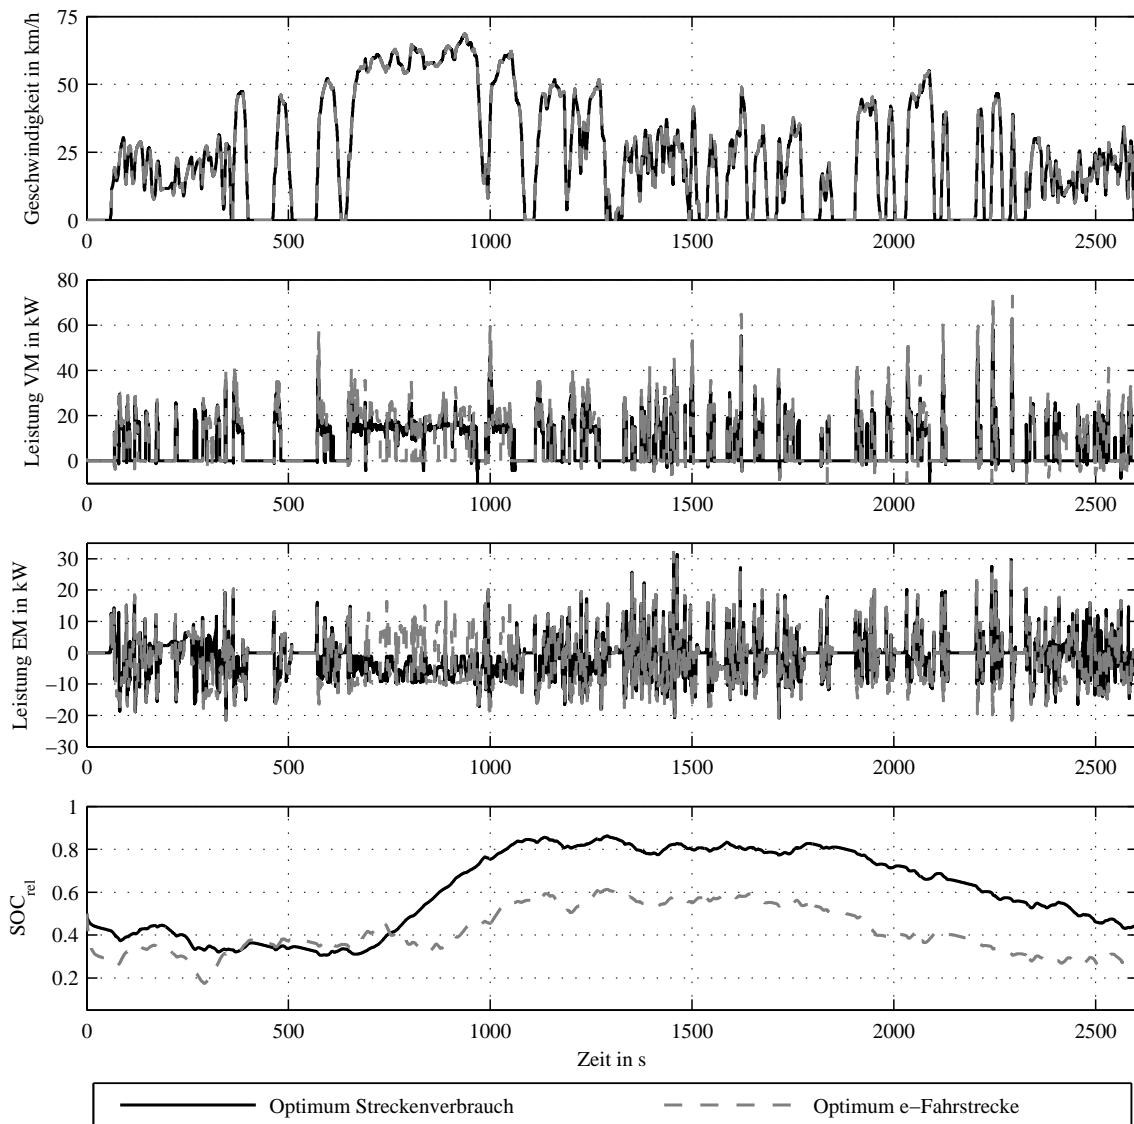


Abbildung 5.18: Simulierte Zeitverläufe im MUC-Stadtzyklus der beiden Eckpunkte der approximierten Pareto-Front von Problemstellung  $P1$

den vorangegangenen Beispielen macht sich die Höhe der e-Fahrleistung im SOC-Niveau bemerkbar. Trotz der relativ niedrigen Grenzleistung für e-Fahren werden in beiden Fällen Leistungen an der E-Maschine von bis zu 30 kW abgerufen. Durch das in

### *5.3 Betriebsstrategieoptimierung im Kundenzyklus*

Abschnitt 4.1.2 beschriebene Systemverhalten beim Verbrennungsmotorzustart muss die E-Maschine den Fahrerwunsch auch nach der Zustartanforderung noch kurzzeitig bis zu 1 s alleine stellen. Je größer die Beschleunigung ist, desto mehr elektrische Energie wird während des Zustarts benötigt.



# Kapitel 6

## Zusammenfassung und Ausblick

Das Ziel dieser Arbeit war die Entwicklung einer Applikationsmethode zur Optimierung der Betriebsstrategieparametrierung von Hybridelektrofahrzeugen. Das Verfahren wurde im realen Serienentwicklungsprozess eines Parallelhybridfahrzeugs über drei Jahre hinweg entwickelt und erprobt.

Um realitätsnahe Aussagen zum Kraftstoffverbrauch zu ermöglichen wurde ein Antriebsprüfstand aufgebaut, bei dem Verbrennungsmotor, E-Maschine und Getriebe sowie dazugehörige Steuergeräte als Hardware vorhanden sind. Modelle von Fahrzeug, Fahrer und Hochvolt Speicher befähigen den Prüfstand zum Fahren von gesetzlichen Fahrzyklen und definierten Fahrmanövern. Die Abbildungsgüte des realen Fahrzeugs am Prüfstand wurde am Beispiel eines NEFZ-Profiles mithilfe einer Energieanalyse gegenübergestellt und bewertet.

Die Basis für die Betriebsstrategieoptimierung bildet ein Simulationsframework in Matlab/Simulink, welches eine einfache Einbindung der realen Steuergerätefunktionen erlaubt. Dabei stehen verschiedene Simulationsmodi zur Verfügung, die über eine GUI gesteuert werden. Diese ermöglicht auch den Austausch von Optimierungsergebnissen und Algorithmusgrundeinstellungen. Ferner können Kalibrierungsparameter vom Fahrzeug oder vom Prüfstand eingelesen bzw. als Ergebnis einer Optimierung exportiert werden.

Für die Optimierung wurde ein genetischer Algorithmus (NSGA-II) ausgewählt und in das Simulationsframework integriert. Für das nichtlineare, nicht stetige, multimodale und diskrete Black-Box-Optimierungsproblem ist der verwendete Algorithmus eine effiziente und robuste Lösungsmethode. Des Weiteren wurden im Rahmen der Algorithmusauswahl Vor- und Nachteile verschiedener Optimierungsansätze erörtert. Durch Einführung einer Diskretisierung und einer Berechnungshistorie sowie adaptiver Abbruchkriterien wird die Optimierungsdauer beim verwendeten Algorithmus klein gehalten.

Das Simulationsframework und der Antriebsprüfstand werden für die Betriebsstra-

tegieoptimierung und -validierung kombiniert. In einem iterativen Prozess können die Betriebsstrategiefunktionen hinsichtlich verschiedener Zielkriterien parametrisiert werden. Der Prüfstand wird dabei als Validierungsplattform eingesetzt.

Die vorgestellte Methode für die Optimierung der Betriebsstrategie wurde am Beispiel der gesetzlichen Zyklen NEFZ und FTP-72 sowie anhand eines kundennahen Stadtfahrprofils eingesetzt. Es wurden drei Problemstellungen identifiziert, bei denen der Kraftstoffverbrauch als wichtigste Zielgröße jeweils im Konflikt mit einem weiteren Zielkriterium steht. Der Suchraum konnte in den gezeigten Beispielen auf drei Dimensionen begrenzt werden. Dafür wurden die wesentlichen Stellhebel der energetischen Betriebsstrategie identifiziert und letztlich auf drei Haupteinflussparameter reduziert.

Mithilfe des Pareto-basierten genetischen Algorithmus lassen sich die möglichen Kompromisslösungen gut im Zielfunktionsraum darstellen. Des Weiteren können Sensitivitäten zwischen den Entscheidungsvariablen und Zielgrößen aufgezeigt werden. Die Problemstellungen wurden bewusst nur mit zwei Zielfunktionen definiert. Neben der besseren Visualisierung der Ergebnisse war auch die Anzahl der Individuen und damit die Gesamtrechenzeit des Algorithmus ausschlaggebend für die Zielfunktionsdefinition.

Da die Energiebilanz einen signifikanten Einfluss auf die gewählten Zielgrößen  $t_{el}$ ,  $s_{el}$  und  $E_{bat,int}$  hat, wird eine SOC-neutrale Simulation angestrebt. Der Korrekturbereich für den Kraftstoffverbrauch wird sehr klein gewählt um die Zielgrößen nicht zu verfälschen. Dadurch sind in der Regel pro Individuum mindestens zwei Simulationsdurchläufe notwendig.

Die Ergebnisse von NEFZ, FTP-72 und MUC-Stadtzyklus zeigen vergleichbare Lösungsmuster im Ziel- und Suchraum. Zusammenfassend lässt sich festhalten, dass immer ein Gleichgewicht zwischen Energieeinnahmen und -ausgaben anzustreben ist. Davon ausgehend konnten im Laufe der Arbeit für den regelbasierten Betriebsstrategieansatz eine Reihe von Modifikationen in Form von adaptiven Funktionen erarbeitet werden. Da in den gesetzlichen Zyklen der Kraftstoffverbrauch die übergeordnete Zielgröße ist, eignen sich die gefundenen Alternativlösungen vor allem für fahrmodusabhängige Ausprägungen des Hybridantriebs.

Die gezeigten Optimierungsprobleme benötigten jeweils zwischen 6 h und 10 h Rechenzeit. Damit konnte die Forderung nach einer akzeptablen Berechnungsdauer für die Anwendung im Serienentwicklungsprozess erfüllt werden. Die Anzahl der Zielfunktionen und Entscheidungsvariablen sowie deren Einfluss auf die Konvergenzgeschwindigkeit muss bei der Problemformulierung beachtet werden.

Die approximierten Pareto-Fronten konnten mithilfe des Prüfstandaufbaus am realen Antriebsstrang durch Auswertung einzelner Lösungspunkte validiert werden. Die ermit-

telten Zielfunktionswerte hatten lediglich minimale Abweichungen von den simulierten Werten.

Neben der multikriteriellen Optimierung gibt es zahlreiche weitere Anwendungsmöglichkeiten für das vorgestellte Framework. Die Rückwärtssimulation erlaubt eine exakte Nachstellung von Fehlerfällen und Fehleranalyse mithilfe der aufgezeichneten Messdaten. Darüber hinaus können Funktionsänderungen sowie deren Schnittstellen bereits vor dem Ersteinsatz im Fahrzeug getestet und parametrisiert werden.

Zusammenfassend lässt sich festhalten, dass die Kombination der Plattformen Simulation und Antriebsprüfstand für die Applikation der Betriebsstrategie in Hybridelektrofahrzeugen gewinnbringend über den gesamten Entwicklungsprozess eingesetzt werden kann. Der Prüfstand ermöglicht realitätsnahe Verbrauchs- und Energieanalysen unter reproduzierbaren Bedingungen. Voraussetzung hierfür ist die parallele Hochrüstung aller Hardwarekomponenten und Steuergeräte analog zu den Fahrzeugversuchsträgern. Als weiterer Vorteil der entwickelten Methodik lässt sich die hohe zeitliche Verfügbarkeit hervorheben.

Die Methodik soll zukünftig auch für Plug-In-Hybridfahrzeugkonzepte zum Einsatz kommen. Die längeren Testverfahren zur Kraftstoffverbrauchsbestimmung erfordern Verbesserungen bei der Berechnungsdauer um Ergebnisse in angemessener Zeit zu erhalten. Weitere Untersuchungen zur Konvergenzgeschwindigkeit des Algorithmus eröffnen mitunter ein zusätzliches Zeitpotenzial.

Ebenfalls denkbar ist die Nutzung des Simulationsframeworks in Verbindung mit der multikriteriellen Optimierung zur Auslegung von Antriebssträngen in der Konzeptphase. Hierfür müssen die Komponentenmodelle von Verbrennungsmotor, E-Maschine und Hochvolt-Speicher skalierbar gestaltet werden.





# Abkürzungs- und Symbolverzeichnis

## Abkürzungen und Akronyme

$CO_2$	Kohlenstoffdioxid
AKF	Aktivkohlefilter
BMW	Bayerische Motorenwerke
DC	Direct Current
e-Fahren	elektrisches Fahren
ECU	Electronic Control Unit
EKMV	Elektrischer Kältemittelverdichter
EM	Elektrische Maschine, E-Maschine
FTP	Federal Test Procedure
GA	Genetischer Algorithmus
GUI	Graphical User Interface
HAG	Hinterachsgetriebe
HCU	Hybrid Control Unit
HEV	Hybrid Electric Vehicle - Hybridelektrofahrzeug
HiL	Hardware-in-the-loop
HV	Hochvolt

## *Abkürzungs- und Symbolverzeichnis*

LE	Leistungselektronik
Li-Ion	Lithium-Ionen
LPAb	Lastpunktabsenkung
LPAn	Lastpunktanhebung
MiL	Model-in-the-loop
MSA	Motor-Start-Stopp-Automatik
NEFZ	Neuer Europäischer Fahrzyklus
NSGA	Non-Dominated Sorting Genetic Algorithm
OBD	On-Board-Diagnose
OCV	Open Circuit Voltage
PKW	Personenkraftwagen
PSM	Permanenterregte Synchronmaschine
PSO	Particle Swarm Optimization
PWR	Pulswechselrichter
SBX	Simulated Binary Crossover
SGR	Startergenerator im Riemen
SOC	State of Charge
VM	Verbrennungsmotor
VM-Fahren	verbrennungsmotorisches Fahren

## Griechische Symbole

$\alpha$                       Fahrbahnwinkel

◦

$\beta_k$	Ausbreitungsfaktor	—
$\delta_k$	Störungsfaktor	—
$\eta$	Wirkungsgrad	—
$\eta_m$	Verteilungsindex der Mutation	—
$\eta_n$	Verteilungsindex der Vererbung	—
$\Omega$	Variablenraum, Suchraum	—
$\rho$	Dichte	$\frac{\text{kg}}{\text{m}^3}$
$\Theta_{red,i}$	reduziertes Massenträgheitsmoment	$\text{kg m}^2$

## Indizes

abs	absolut
akt	aktuell
bas	Basisbetriebspunkt
bat	Batterie
chem	chemisch
dyn	dynamisch
eff	effektiv
el	elektrisch
EM	E-Maschine
end	Endwert
entl	Entladen
fzg	Fahrzeug

## *Abkürzungs- und Symbolverzeichnis*

gelenk	Gelenkwelle
gen	generatorisch
ges	gesamt
getr	Getriebe
grenz	Grenze
in	Eingang
ist	Istwert
kst	Kraftstoff
lad	Laden
LPAb	Lastpunktabsenkung
LPAn	Lastpunktanhebung
LPV	Lastpunktverschiebung
max	Maximum
mech	mechanisch
mess	Messwert
min	Minimum
mot	motorisch
opt	optimal
out	Ausgang
par	parallel
pst	Prüfstand
rad	Rad
rel	relativ

rot	rotatorisch
ser	seriell
sim	Simulation
soll	Sollwert
start	Startwert
sum	Summe
trans	translatorisch
VM	Verbrennungsmotor

## Lateinische Symbole

$\Delta SOC$	SOC-Differenz	%
$\Delta T$	Temperaturdifferenz	K
$\dot{m}$	Massenstrom	$\frac{\text{g}}{\text{s}}$
$\mathbf{x}$	Lösungsvektor	—
$\mathbf{z}$	Zielfunktionsvektor	—
$a$	Beschleunigung	$\frac{\text{m}}{\text{s}^2}$
$A$	Aufwand	$\frac{\text{g}}{\text{kWh}}$
$B$	Kraftstoffverbrauch	l
$B_s$	Streckenverbrauch	$\frac{1}{100 \text{ km}}$
$C$	Kapazität	F
$E$	Energie	Wh
$F$	Kraft	N

## Abkürzungs- und Symbolverzeichnis

$g$	Erdbeschleunigung	$\frac{\text{m}}{\text{s}^2}$
$i$	Übersetzung	–
$I$	Strom	A
$k_{f,FTP}$	Korrekturfaktor für den Kraftstoffverbrauch im FTP-72	$\frac{1}{\text{Wh}}$
$k_{f,NEFZ}$	Korrekturfaktor für den Kraftstoffverbrauch im NEFZ	$\frac{1}{\text{Wh}}$
$m$	Masse	kg
$M$	Drehmoment	Nm
$n$	Drehzahl	$\frac{\text{U}}{\text{min}}$
$N$	Nutzen	$\frac{\text{g}}{\text{kWh}}$
$P$	Leistung	W
$p_c$	Wahrscheinlichkeit für Crossover	–
$p_m$	Wahrscheinlichkeit für Mutation	–
$Q$	Ladungsmenge	Ah
$r$	Radius	m
$R$	ohmscher Widerstand	$\Omega$
$s$	Strecke	m
$T$	Temperatur	$^{\circ}\text{C}$
$T_{min,VM}$	Mindestlaufzeit des Verbrennungsmotors	s
$U$	Spannung	V
$Z$	Zielfunktionsraum	–

# Abbildungsverzeichnis

1.1	Verteilung der $CO_2$ -Emissionen in den OECD-Staaten im Jahr 2010 [97]	2
1.2	Vereinfachtes V-Modell zum automobilen Softwareentwicklungsprozess .	4
1.3	Applikationsplattformen Hybrid-Betriebsstrategie . . . . .	6
1.4	Kosten verschiedener Plattformen in Abhängigkeit vom Zeitpunkt im Entwicklungsprozess [154] . . . . .	8
2.1	Mögliche Antriebstopologien für Hybridelektrofahrzeuge . . . . .	13
2.2	Entscheidungsvariablenraum und zugehöriger Zielfunktionsraum . . . .	20
2.3	Darstellung der Pareto-Front als Teilmenge des Zielfunktionsraums . .	21
2.4	Anwendung der Methode der gewichteten Summe bei konvexer (links) und nicht-konvexer (rechts) Menge im Zielfunktionsraum . . . . .	24
2.5	Anwendung der $\epsilon$ -Constraint Methode bei nicht-konvexer Menge im Zielfunktionsraum . . . . .	25
2.6	Ablaufschema eines genetischen Algorithmus . . . . .	30
2.7	Beispielhafte Visualisierung des No-Free-Lunch Theorems nach [78, 202]	34
3.1	Antriebsstrangtopologie des betrachteten Hybridelektrofahrzeugs . . . .	40
3.2	Wirkungsgradkennfeld des Verbrennungsmotors . . . . .	41
3.3	Willans-Linien des Verbrennungsmotors für verschiedene Drehzahlen . .	42
3.4	Wirkungsgradkennfeld der E-Maschine inkl. Leistungselektronik . . . .	43
3.5	Willans-Linien der E-Maschine inkl. Leistungselektronik für verschiedene Drehzahlen . . . . .	44
3.6	Getriebe-topologie 8P70H . . . . .	45
3.7	Klassifikation verschiedener Speichertechnologien im Ragone-Diagramm [198] . . . . .	47
3.8	Aufbau von Prüfzelle und Bedienwarte des Antriebsprüfstands . . . . .	50
3.9	Umsetzung des Fahrzyklusbetriebs am Antriebsprüfstand . . . . .	52
3.10	Reglerstruktur des Fahrpedalreglers am Antriebsprüfstand . . . . .	53

3.11	Definition eines maximal zulässigen Ladeaufwands $A_{max}$ und minimal geforderten Nutzens $N_{min}$ in Abhängigkeit vom SOC [179] . . . . .	55
3.12	Gesamtwirkungsgradoptimierte elektrische Ladeleistung der E-Maschine in Abhängigkeit von Drehmoment und Drehzahl am Getriebeeingang für $A_{max} = 270 \text{ g/kWh}$ . . . . .	57
3.13	Wirkungsgradkette für VM-Fahren und e-Fahren aus Lastpunktanhebung	58
3.14	Qualitative Willans-Darstellung für die e-Fahrentscheidung . . . . .	59
3.15	Abgrenzung des elektrischen und verbrennungsmotorischen Fahrbereichs anhand einer e-Fahrkennlinie . . . . .	60
3.16	Zeitverläufe im NEFZ am Antriebsprüfstand . . . . .	62
4.1	Prinzip der quasistationären Simulation (Rückwärtssimulation) . . . . .	66
4.2	Prinzip der dynamischen Simulation (Vorwärtssimulation) . . . . .	68
4.3	Simulationsframework für die Betriebsstrategieoptimierung (vgl. [178, 177])	69
4.4	Schematischer Ablauf des Zustarts . . . . .	73
4.5	Modell des Hochvoltspeichers . . . . .	75
4.6	Schema der Betriebsstrategie-Applikationsmethode (vgl. [177]) . . . . .	78
4.7	Ablaufplan des implementierten NSGA-II-Algorithmus (vgl. [26, 88]) .	81
4.8	Einteilung nach Fronten zur Bestimmung der <i>crowding distance</i> [88, 50]	82
4.9	Wahrscheinlichkeitsdichte für die Nachkommensbildung durch Rekombination bei unterschiedlichen $n_c$ -Werten ([47]) . . . . .	83
4.10	Wahrscheinlichkeitsdichte für die Nachkommensbildung durch Mutation bei unterschiedlichen $n_m$ -Werten . . . . .	85
4.11	Auswahl der Individuen für die Folgegeneration [88, 50] . . . . .	86
4.12	Zusammenhang zwischen Kraftstoffverbrauch und $\Delta SOC$ im NEFZ . .	90
4.13	Zusammenhang zwischen Kraftstoffverbrauch und $\Delta SOC$ im FTP-72 .	90
4.14	Abhängigkeit der Leerlaufspannung vom SOC beim Laden und Entladen	91
4.15	Umsetzung der SOC-Neutralität im NSGA-II-Algorithmus (vgl. [88]) .	92
5.1	Zeitverläufe im NEFZ von Antriebsprüfstandsmessung und Rückwärtssimulation . . . . .	101
5.2	Optimierungsergebnisse von Problemstellung $P1$ im NEFZ im Zielfunktions- und Variablenraum . . . . .	103
5.3	Optimierungsergebnisse von Problemstellung $P2$ im NEFZ im Zielfunktions- und Variablenraum . . . . .	104
5.4	Approximierte Pareto-Front des Zielkonflikts minimaler Kraftstoffverbrauch und maximale e-Fahrleistung im NEFZ . . . . .	105



5.5	Optimierungsergebnisse von Problemstellung $P3$ im NEFZ im Zielfunktions- und Variablenraum . . . . .	106
5.6	Zielfunktionsraum von Problemstellung $P1$ im NEFZ mit verifizierten Lösungspunkten vom Antriebsprüfstand . . . . .	107
5.7	Simulierte Zeitverläufe im NEFZ der beiden Eckpunkte der approximierten Pareto-Front von Problemstellung $P1$ . . . . .	108
5.8	Zeitverläufe im FTP-72 von Antriebsprüfstandsmessung und Rückwärts-simulation . . . . .	109
5.9	Optimierungsergebnisse von Problemstellung $P1$ im FTP-72 im Zielfunktions- und Variablenraum . . . . .	111
5.10	Optimierungsergebnisse von Problemstellung $P2$ im FTP-72 im Zielfunktions- und Variablenraum . . . . .	112
5.11	Approximierte Pareto-Front des Zielkonflikts minimaler Kraftstoffver- brauch und maximale e-Fahrleistung im FTP-72 . . . . .	113
5.12	Simulierte Zeitverläufe im FTP-72 der beiden Eckpunkte der approxi- mierten Pareto-Front in Abbildung 5.12 . . . . .	114
5.13	Simulierte Zeitverläufe im FTP-72 der beiden Eckpunkte der approxi- mierten Pareto-Front von Problemstellung $P1$ . . . . .	115
5.14	Zielfunktionsraum von Problemstellung $P1$ im FTP-72 mit verifizierten Lösungspunkten vom Antriebsprüfstand . . . . .	116
5.15	Optimierungsergebnisse von Problemstellung $P3$ im FTP-72 im Zielfunktions- und Variablenraum . . . . .	117
5.16	Optimierungsergebnisse von Problemstellung $P1$ im MUC-Stadtzyklus im Zielfunktions- und Variablenraum . . . . .	118
5.17	Approximierte Pareto-Front des Zielkonflikts minimaler Kraftstoffver- brauch und maximale e-Fahrleistung im MUC-Stadtzyklus . . . . .	119
5.18	Simulierte Zeitverläufe im MUC-Stadtzyklus der beiden Eckpunkte der approximierten Pareto-Front von Problemstellung $P1$ . . . . .	120



# Tabellenverzeichnis

3.1	Schaltschema 8P70H-Getriebe . . . . .	46
3.2	Technische Daten des betrachteten Fahrzeugs . . . . .	49
3.3	Technische Daten des Prüfstands . . . . .	51
3.4	Auswertung von Fahrzeug- und Prüfstandsmessung im NEFZ-Zyklus . . . . .	63
5.1	Variablengrenzen für die Betriebsstrategieoptimierung . . . . .	98
5.2	Ergebnisübersicht der Optimierungsprobleme $P1$ und $P2$ im FTP-72 . . . . .	113



# Literaturverzeichnis

- [1] ALBERS, A. ; GSCHWEITL, K. ; SCHYR, C. ; KUNZFELD, S.: Methoden und Werkzeuge zur modellbasierten Validierung von Hybridantrieben. In: *ATZ-Automobiltechnische Zeitschrift* 108 (2006), S. 980–987
- [2] AMBÜHL, D. ; SCIARRETTA, A. ; ONDER, C. ; GUZZELLA, L. ; STERZING, S. ; MANN, K. ; KRAFT, D. ; KÜSELL, M.: A causal operation strategy for hybrid electric vehicles based on optimal control theory. In: *4th Symposium Hybrid Vehicles and Energy Management*. Braunschweig, Germany, 2007
- [3] AO, G.-Q. ; QIANG, J.-X. ; ZHONG, H. ; MAO, X.-J. ; YANG, L. ; ZHUO, B.: Fuel economy and NOx emission potential investigation and trade-off of a hybrid electric vehicle based on dynamic programming. In: *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering* 222 (2008), Nr. 10, S. 1851–1864
- [4] ARGONNE NATIONAL LABORATORY: *Autonomie*. Website. URL:<http://www.autonomie.net/>. – (letzter Abruf am 30.01.2012)
- [5] ARGONNE NATIONAL LABORATORY: *Powertrain System Analysis Toolkit (PSAT)*. Website. URL:<http://www.transportation.anl.gov/>. – (letzter Abruf am 30.01.2012)
- [6] ASADA, T. ; SAKAI, K.: Das neue Stop & Start System von Toyota. In: *17. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 6–8, 2008
- [7] AVL: *Homepage*. Website. URL:<http://www.avl.com/>. – (letzter Abruf am 30.03.2013)
- [8] AVL LIST GMBH: *Product Guide AVL FUELEXACT*. 2008

- [9] BACK, M.: *Prädiktive Antriebsregelung zum energieoptimalen Betrieb von Hybridfahrzeugen*, Schriften des Instituts für Regelungs- und Steuerungssysteme, Universität Karlsruhe (TH), Diss., 2005
- [10] BÄCK, T. ; FOGEL, D.B. ; MICHALEWICZ, Z.: *Handbook of evolutionary computation*. Institute of Physics Publishing, Bristol, UK and Oxford University Press, New York, 1997
- [11] BAUCHROWITZ, E. ; GRAF, H. ; KESSLER, F. ; LICHTENBERGER, M.: Der Hybridantrieb im BMW ActiveHybrid 7. In: *ATZ-Automobiltechnische Zeitschrift* 112 (2010), Nr. 9, S. 628
- [12] BECK, R. ; BOLLIG, A. ; ABEL, D.: Echtzeitstrategien zum Prädiktiven Optimalen Energiemanagement in Hybridfahrzeugen. In: *VDI-Berichte „Innovative Fahrzeugantriebe“* (2006), Nr. 1775, S. 557–560
- [13] BERTRAM, C. ; BUECHERL, D. ; THANHEISER, A. ; HERZOG, H.-G.: Multi-objective optimization of a parallel hybrid electric drive train. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)*. Chicago, IL, USA, September 6–9, 2011
- [14] BIER, M. ; BUCH, D. ; KLUIN, M. ; BEIDL, C.: Entwicklung und Optimierung von Hybridantrieben am X-in-the-Loop-Motorenprüfstand. In: *MTZ-Motortechnische Zeitschrift* 73 (2012), Nr. 3, S. 240–247
- [15] BIER, M. ; KLUIN, M. ; BEIDL, C.: Strukturierte Betriebsstrategie für Hybridfahrzeuge. In: *ATZextra* 17 (2012), Nr. 5, S. 94–99
- [16] BOCK, C. ; KLÜTING, M. ; RABENSTEIN, F.: Moderne Applikationsmethoden - ein unverzichtbarer Baustein bei der Entwicklung des innovativen neuen BMW V8 Ottomotors. In: *17. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 6–8, 2008
- [17] BÖCKL, M.: *Adaptives und prädiktives Energiemanagement zur Verbesserung der Effizienz von Hybridfahrzeugen*, Institut für Verbrennungskraftmaschinen und Kraftfahrzeugbau, Technische Universität Wien, Diss., 2008
- [18] BÖHLE, J. ; STIEBELS, B.: Der neue Touareg Hybrid. In: *ATZextra–Der VW Touareg* 2 (2010)

- [19] BÖHM, M. ; STEGMAIER, N. ; BAUMANN, G. ; REUSS, H.-C.: Der Neue Antriebsstrang- und Hybrid-Prüfstand der Universität Stuttgart. In: *MTZ-Motortechnische Zeitschrift* 72 (2011), Nr. 9, S. 698–701
- [20] BOHNE, W. ; PÖLTENSTEIN, A. ; BRAVO, I. ; JUNG, M.: Die Entwicklung vernetzter Funktionen im hybriden Antriebsstrang. In: *16. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 8–10, 2007
- [21] BRADLEY, T.H. ; FRANK, A.A.: Design, demonstrations and sustainability impact assessments for plug-in hybrid electric vehicles. In: *Renewable and Sustainable Energy Reviews* 13 (2009), Nr. 1, S. 115–128
- [22] BRAUN, H.S. ; KRAUSS, M. ; RATTEI, F. ; BOHNE, W. ; ENGELMANN, M. ; DEUKE, U. ; DI PIERRO, M.: Der Vollhybridantrieb im ActiveHybrid X6 von BMW. In: *ATZ-Automobiltechnische Zeitschrift* 111 (2009), Nr. 11, S. 792
- [23] BROTZ, F. ; ISERMAYER, T. ; PFENDER, C. ; HECKENBERGER, T.: Entwicklung-Batteriekühlung: Kühlung von Hochleistungsbatterien für Hybridfahrzeuge. In: *ATZ-Automobiltechnische Zeitschrift* 109 (2007), Nr. 12, S. 1156–1163
- [24] BÜCHERL, D. ; HERZOG, H.-G. ; ENGSTLE, A.: Energetische Betrachtung der Lastpunktanhebung als Maßnahme zur Kraftstoffreduktion in Hybridfahrzeugen. In: *Elektrisch-mechanische Antriebssysteme (ETG-Fachbericht 113)* (2008)
- [25] BURETTE, G. ; PEREZ, F. ; BANSAL, K.: Vehicle calibration optimization using a dynamic test bed with real time vehicle simulation. In: *SIA International Conference*, 2010
- [26] BÜRGER, S.: *Multikriterielle Optimierung von Hybridantriebskonzepten hinsichtlich Verbrauch und Dynamik*, Lehrstuhl für Regelungstechnik, Technische Universität München, Diss., 2012
- [27] BÜRGER, S. ; LOHMANN, B. ; MERZ, M. ; VOGEL-HEUSER, B. ; HALLMANNSEGER, M.: Multi-Objective Optimization of Hybrid Electric Vehicles Considering Fuel Consumption and Dynamic Performance. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)*. Lille, France, September 1–3, 2010
- [28] BURRESS, T.A. ; COOMER, C.L. ; CAMPBELL, S.L. ; WERESZCZAK, A.A. ; CUNNINGHAM, J.P. ; MARLINO, L.D. ; SEIBER, L.E. ; LIN, H.T.: Evaluation of

- the 2008 LEXUS LS 600h hybrid synergy drive system / Oak Ridge National Laboratory (ORNL), Oak Ridge, TN. 2009. – Forschungsbericht
- [29] CANTÚ-PAZ, E.: *Efficient and accurate parallel genetic algorithms*. Bd. 1. Springer, 2000
- [30] CARB: *Homepage*. Website. URL:<http://www.arb.ca.gov/homepage.htm>. – (letzter Abruf am 30.04.2013)
- [31] CARVALHO, A.G. ; ARAUJO, A.F.R.: Improving NSGA-II with an adaptive mutation operator. In: *Proceedings of the 11th Annual Conference Companion on Genetic and Evolutionary Computation Conference: Late Breaking Papers*, 2009, S. 2697–2700
- [32] CHASSE, A. ; SCIARRETTA, A. ; CHAUVIN, J.: Online optimal control of a parallel hybrid with costate adaptation rule. In: *6th IFAC Symposium Advances in Automotive Control*, 2010, S. 99–104
- [33] CHEN, J.S. ; SALMAN, M.: Learning energy management strategy for hybrid electric vehicles. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)* IEEE, 2005, S. 68–73
- [34] CHEN, Z. ; MI, C.C.: An adaptive online energy management controller for power-split HEV based on Dynamic Programming and fuzzy logic. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)*. Dearborn, MI, September 7–10, 2009, S. 335–339
- [35] CHENG, C. ; MCGORDON, A. ; JONES, R.P. ; JENNINGS, P.A.: Comprehensive forward dynamic HEV powertrain modelling using Dymola and MATLAB/Simulink. In: *6th IFAC Symposium Advances in Automotive Control*. Munich, Germany, 2010, S. 536–541
- [36] CHRIST, T.: Bremsenergieerückgewinnung im elektrischen Bordnetz. In: *ATZelektronik* 4 (2009), Nr. 4, S. 10–17
- [37] COELLO, C. A. C.: An updated survey of GA-based multiobjective optimization techniques. In: *ACM Computing Surveys (CSUR)* 32 (2000), Nr. 2, S. 109–143
- [38] COELLO, C.A.C. ; LAMONT, G.B. ; VAN VELDHUIZEN, D.A.: *Evolutionary algorithms for solving multi-objective problems*. Bd. 5. New York, USA : Springer-Verlag, 2007



- [39] COOK, R. ; MOLINA-CRISTOBAL, A. ; PARKS, G. ; CORREA, C. O. ; CLARKSON, P. J.: Multi-objective optimisation of a hybrid electric vehicle: drive train and driving strategy. In: *Proceedings of the 4th international conference on Evolutionary multi-criterion optimization*. Berlin, Heidelberg : Springer-Verlag, 2007 (EMO'07), S. 330–345
- [40] D2T: *Homepage*. Website. URL:<http://www.d2t.com/>. – (letzter Abruf am 30.03.2013)
- [41] DAS EUROPÄISCHE PARLAMENT UND DER RAT DER EUROPÄISCHEN UNION: *Verordnung (EG) Nr. 443/2009 des europäischen Parlaments und des Rates vom 23. April 2009 zur Festsetzung von Emissionsnormen für neue Personenkraftwagen im Rahmen des Gesamtkonzepts der Gemeinschaft zur Verringerung der CO<sub>2</sub>-Emissionen von Personenkraftwagen und leichten Nutzfahrzeugen*. 2009
- [42] DAS EUROPÄISCHE PARLAMENT UND DER RAT DER EUROPÄISCHEN UNION: *Richtlinie 2007/46/EG des europäischen Parlaments und des Rates zur Schaffung eines Rahmens für die Genehmigung von Kraftfahrzeugen und Kraftfahrzeuganhängern sowie von Systemen, Bauteilen und selbstständigen technischen Einheiten für diese Fahrzeuge*. September 2007
- [43] DEB, K.: *Multi-objective optimization using evolutionary algorithms*. Wiley, 2004
- [44] DEB, K. ; AGRAWAL, R.B.: Simulated binary crossover for continuous search space. In: *Complex systems* 9 (1995), Nr. 2, S. 115–148
- [45] DEB, K. ; AGRAWAL, S. ; PRATAP, A. ; MEYARIVAN, T.: A Fast Elitist Non-dominated Sorting Genetic Algorithm for Multi-objective Optimisation: NSGA-II. In: *Proceedings of the 6th International Conference on Parallel Problem Solving from Nature* Springer-Verlag, 2000, S. 849–858
- [46] DEB, K. ; BEYER, H.-G.: Self-adaptation in real-parameter genetic algorithms with simulated binary crossover. In: *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO)*, 1999, S. 172–179
- [47] DEB, K. ; BEYER, H.-G.: Self-adaptive genetic algorithms with simulated binary crossover. In: *Evolutionary Computation* 9 (2001), Nr. 2, S. 197–221
- [48] DEB, K. ; GOYAL, M.: A combined genetic adaptive search (GeneAS) for engineering design. In: *Computer Science and Informatics* 26 (1996), S. 30–45

- [49] DEB, K. ; KUMAR, A.: Real-coded genetic algorithms with simulated binary crossover: Studies on multimodal and multiobjective problems. In: *Complex Systems* 9 (1995), Nr. 6, S. 431–454
- [50] DEB, K. ; PRATAP, A. ; AGARWAL, S. ; MEYARIVAN, T.: A fast and elitist multi-objective genetic algorithm: NSGA-II. In: *IEEE Transactions on Evolutionary Computation* 6 (2002), Nr. 2, S. 182–197
- [51] DEB, K. ; SINDHYA, K. ; OKABE, T.: Self-adaptive simulated binary crossover for real-parameter optimization. In: *Proceedings of the Genetic and Evolutionary Computation Conference (GECCO)*, 2007, S. 1187–1194
- [52] DELPRAT, S. ; GUERRA, T.M. ; RIMAU, J.: Control strategies for hybrid vehicles: synthesis and evaluation. In: *58th Vehicular Technology Conference (VTC)* Bd. 5, 2003, S. 3246–3250
- [53] DESAI, C. ; WILLIAMSON, S.S.: Optimal design of a parallel Hybrid Electric Vehicle using multi-objective genetic algorithms. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)* IEEE, 2009, S. 871 –876
- [54] DEXTREIT, C. ; ASSADIAN, F. ; KOLMANOVSKY, I.V. ; MAHTANI, J. ; BURNHAM, K.: Hybrid electric vehicle energy management using game theory. In: *SAE Technical Paper 2008-01-1317* (2008)
- [55] DHALIWAL, A. ; NAGARAJ, S. ; ALI, S.: Hardware-in-the-Loop Simulation for Hybrid Electric Vehicles – An Overview, Lessons Learned and Solutions Implemented. In: *SAE Technical Paper 2009-01-0735* (2009)
- [56] DIE KOMMISSION DER EUROPÄISCHEN GEMEINSCHAFTEN: *Empfehlung 1999/125/EG der Kommission vom 5. Februar 1999 über die Minderung der CO<sub>2</sub>-Emissionen von Personenkraftwagen*
- [57] DIE KOMMISSION DER EUROPÄISCHEN GEMEINSCHAFTEN: *KOM(2007)19 Mitteilung der Kommission an den Rat und das europäische Parlament über die Ergebnisse der Überprüfung der Strategie der Gemeinschaft zur Minderung der CO<sub>2</sub>-Emissionen von Personenkraftwagen und leichten Nutzfahrzeugen.* 2007
- [58] DORIGO, M. ; DI CARO, G.: Ant colony optimization: a new meta-heuristic. In: *Proceedings of the 2009 Congress on Evolutionary Computation (CEC)* Bd. 2 IEEE, 1999

- [59] DSPACE: *Homepage*. Website. URL:<http://www.dspace.com/>. – (letzter Abruf am 30.03.2013)
- [60] DUDENREDAKTION: *Duden – Das große Fremdwörterbuch*. Mannheim; Leipzig; Wien; Zürich: Dudenverlag : Bibliographisches Institut & F.A. Brockhaus AG, 2000
- [61] DUHME, M. ; ZETINA, S. S. ; NEISS, K.: Der Mercedes-Benz ML 450 HYBRID und das Potenzial des elektrischen CVT-Getriebes. In: *18. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 5–7, 2009
- [62] EBERHART, R. ; SHI, Y.: Comparison between genetic algorithms and particle swarm optimization. In: *Evolutionary Programming VII* Springer, 1998, S. 611–616
- [63] EIBEN, A.E. ; SCHIPPERS, C.A.: On evolutionary exploration and exploitation. In: *Fundamenta Informaticae* 35 (1998), Nr. 1, S. 35–50
- [64] EICHLSEDER, H. ; KLÜTING, M. ; PIOCK, W.F.: *Grundlagen und Technologien des Ottomotors*. Springer, 2007
- [65] ELBELTAGI, E. ; HEGAZY, T. ; GRIERSON, D.: Comparison among five evolutionary-based optimization algorithms. In: *Advanced engineering informatics* 19 (2005), Nr. 1, S. 43–53
- [66] ELECTRICAL ENGINEERING DEPARTMENT, UNIVERSITY OF SOUTH CAROLINA, COLUMBIA, SC, USA: *Virtual Test Bed (VBT)*. Website. URL:<http://vtb.ee.sc.edu/>. – (letzter Abruf am 30.01.2012)
- [67] ESHELMAN, L.J.: The CHC adaptive search algorithm: How to have safe search when engaging in nontraditional genetic recombination. In: *Foundations of genetic algorithms 1* (1991), S. 265–283
- [68] ESHELMAN, L.J. ; CARUANA, R.A. ; SCHAFFER, J.D.: Biases in the crossover landscape. In: *Proceedings of the third international conference on Genetic algorithms* Morgan Kaufmann Publishers Inc., 1989, S. 10–19
- [69] ETAS: *Homepage*. Website. URL:<http://www.etas.com/>. – (letzter Abruf am 30.03.2013)
- [70] FANG, L. ; QIN, S. ; XU, G. ; LI, T. ; ZHU, K.: Simultaneous Optimization for Hybrid Electric Vehicle Parameters Based on Multi-Objective Genetic Algorithms. In: *Energies* 4 (2011), Nr. 3, S. 532–544

- [71] FLECKNER, M. ; GÖHRING, M. ; SPIEGEL, L.: Neue Strategien zur verbrauchsoptimalen Auslegung der Betriebsführung von Hybridfahrzeugen. In: *18. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 5–7, 2009
- [72] FOGEL, D.B.: An overview of evolutionary programming. In: *Institute for Mathematics and Its Applications* 111 (1999), S. 89
- [73] FRANK, A.A.: Plug-in Hybrid Vehicles for a Sustainable Future. In: *American Scientist* 95 (2007), Nr. 2, S. 158–165
- [74] FRITZSON, P.A.: *Introduction to Modeling and Simulation of Technical and Physical Systems with Modelica*. Wiley-IEEE Press, 2011
- [75] GAO, D. ; MI, C. ; EMADI, A.: Modeling and Simulation of Electric and Hybrid Vehicles. In: *Proc. of the IEEE* Bd. 95, 2007, S. 729–745
- [76] GLOVER, F. ; LAGUNA, M.: *Tabu Search*. (1997)
- [77] GMELIN, A. C.: *Dynamik- und Verbrauchsoptimierung eines Parallel-Hybridfahrzeugs mit Hilfe eines multikriteriellen Genetischen Algorithmus*, Lehrstuhl für Regelungstechnik, Technische Universität München, Diplomarbeit, 2012
- [78] GOLDBERG, D.E.: *Genetic algorithms in search, optimization, and machine learning*. Addison-Wesley, 1989
- [79] GOLDBERG, D.E. ; DEB, K.: A comparative analysis of selection schemes used in genetic algorithms. In: *Foundations of Genetic Algorithms 1*, 1991, S. 69–93
- [80] GOLDBERG, D.E. ; DEB, K. ; CLARK, J.H.: Genetic algorithms, noise, and the sizing of populations. In: *Complex systems* 6 (1992), Nr. 4, S. 333–362
- [81] GOLDBERG, D.E. ; DEB, K. ; THIERENS, D.: Toward a better understanding of mixing in genetic algorithms. In: *Journal of the Society of Instrument and Control Engineers* 32 (1993), Nr. 1, S. 10–16
- [82] GUSTAV KLEIN GMBH & CO. KG: *Homepage*. Website. URL:<http://www.gustav-klein.de/>. – (letzter Abruf am 30.04.2013)
- [83] HAFKEMEYER, M. ; EL-DWAIK, F. ; HEIM, A. ; LIEBL, J. ; STAUBER, J. ; TRAUB, F.: Effiziente Dynamik durch intelligentes Energiemanagement. In: *VDI-Berichte „Elektronik im Kraftfahrzeug“* (2005), Nr. 1907

- [84] HANSEN, M.P. ; JASZKIEWICZ, A.: Evaluating the quality of approximations to the non-dominated set / Institute of Mathematical Modelling, Technical University of Denmark. 1998. – Forschungsbericht
- [85] HARIK, G. ; CANTÚ-PAZ, E. ; GOLDBERG, D.E. ; MILLER, B.L.: The gambler's ruin problem, genetic algorithms, and the sizing of populations. In: *Evolutionary Computation* 7 (1999), Nr. 3, S. 231–253
- [86] HASSAN, R. ; COHANIM, B. ; DE WECK, O. ; VENTER, G.: A Comparison Of Particle Swarm Optimization And The Genetic Algorithm. In: *46 th AIAA/ASME/ASCE/AHS/ASC Structures, Structural Dynamics, and Materials Conference*, 2005, S. 1–13
- [87] HERRERA, F. ; LOZANO, M. ; VERDEGAY, J.L.: Tackling real-coded genetic algorithms: Operators and tools for behavioural analysis. In: *Artificial intelligence review* 12 (1998), Nr. 4, S. 265–319
- [88] HILDEBRANDT, C.: *Optimierung des Ladezustandsmanagements in der Hybridserienentwicklung am Antriebsprüfstand*, Technische Universität Dresden, Lehrstuhl für Fahrzeugmechatronik, Diplomarbeit, 2012
- [89] HOFMAN, T. ; STEINBUCH, M. ; VAN DRUTEN, R. ; SERRARENS, A.: Rule-based energy management strategies for hybrid vehicles. In: *International Journal of Electric and Hybrid Vehicles* 1 (2007), Nr. 1, S. 71–94
- [90] HOFMANN, P.: *Hybridfahrzeuge: Ein alternatives Antriebskonzept für die Zukunft*. Springer, 2009
- [91] HOLLAND, J.H.: *Adaptation in natural and artificial systems*. MIT Press, Cambridge, MA, USA, 1992
- [92] HOLLAND, J.H.: Genetic algorithms. In: *Scientific american* 267 (1992), Nr. 1, S. 66–72
- [93] HU, X. ; WANG, Z. ; LIAO, L.: Multi-objective optimization of HEV fuel economy and emissions using evolutionary computation. In: *SAE SP* (2004), S. 117–128
- [94] HUANG, B. ; WANG, Z. ; XU, Y.: Multi-Objective Genetic Algorithm for Hybrid Electric Vehicle Parameter Optimization. In: *Intelligent Robots and Systems, 2006 IEEE/RSJ International Conference on IEEE*, 2006, S. 5177–5182

- [95] HUI, Z. ; CHENG, L. ; GUOJIANG, Z.: Design of a versatile test bench for hybrid electric vehicles. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)*. Harbin, China, September 3–5, 2008
- [96] HÜTTER, A.: *Verkehr auf einen Blick*. Statistisches Bundesamt, Wiesbaden, Germany, 2013
- [97] INTERNATIONAL ENERGY AGENCY (IEA): *CO<sub>2</sub> Emissions from fuel combustion—highlights*. 2012
- [98] JEON, S. ; JO, S. ; PARK, Y. ; LEE, J.: Multi-mode driving control of a parallel hybrid electric vehicle using driving pattern recognition. In: *Journal of Dynamic Systems, Measurement and Control* 124 (2002), Nr. 1, S. 141–149
- [99] JOHANNESSON, L.: *Predictive control of hybrid electric vehicles on prescribed routes*, Department of Signals and Systems, Chalmers University of Technology Göteborg, Diss., 2009
- [100] JOHN, F.: *Optimierung der Ladezustandsregelung in einem parallelen Hybridantrieb*, Hochschule München, Diplomarbeit, 2010
- [101] JÖRG, A. ; SCHRÖDER, D.: Predictive Real Time Energymanagement for Hybrid Cars using Mixed Integer Linear Programming. In: *2nd CTI Symposium Automotive Transmissions*. Detroit, MI, 2008
- [102] KEMPER, H. ; RÜTTEN, O. ; JENTGES, M. ; SCHLOSSER, A.: Betriebsstrategien von Hybridfahrzeugen, Funktionen und Applikation. In: *15. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 9–11, 2006
- [103] KENNEDY, J. ; EBERHART, R.: Particle swarm optimization. In: *Proceedings of the IEEE International Conference on Neural Networks* Bd. 4 IEEE, 1995, S. 1942–1948
- [104] KESSELS, J. ; KOOT, M. ; VAN DEN BOSCH, P. ; KOK, D.: Online energy management for hybrid electric vehicles. In: *IEEE Transactions on Vehicular Technology* 57 (2008), Nr. 6, S. 3428–3440
- [105] KETTERER, B. ; KARL, U. ; MÖST, D. ; ULRICH, S.: Lithium-Ionen Batterien: Stand der Technik und Anwendungspotenzial in Hybrid-, Plug-In Hybrid- und

- Elektrofahrzeugen. In: *Wissenschaftliche Berichte FZKA 7503, Forschungszentrum Karlsruhe in der Helmholtz-Gemeinschaft Institut für Materialforschung I*, (2009)
- [106] KHEIR, N.A. ; SALMAN, M.A. ; SCHOUTEN, N.J.: Emissions and fuel economy trade-off for hybrid vehicles using fuzzy logic. In: *Mathematics and Computers in Simulation* 66 (2004), Nr. 2-3, S. 155–172
- [107] KILLMANN, G. ; TAKAOKA, T.: Der Hybridantrieb des neuen Toyota Prius. In: *18. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 5–7, 2009
- [108] KIRKPATRICK, S. ; GELATT, C.D. ; VECCHI, M.P.: Optimization by simulated annealing. In: *Science* 220 (1983), Nr. 4598, S. 671–680
- [109] KLAUER, N. ; KRETSCHMER, J. ; UNGER, H.: Der Antrieb des BMW 535i Gran Turismo. In: *ATZ-Automobiltechnische Zeitschrift* 111 (2009), S. 610–617
- [110] KLEIMAIER, A.: *Optimale Betriebsführung von Hybridfahrzeugen*, Lehrstuhl für Elektrische Antriebssysteme, Technische Universität München, Diss., 2003
- [111] KLEIMAIER, A. ; SCHRÖDER, D.: An approach for the online optimized control of a hybrid powertrain. In: *7th International Workshop on Advanced Motion Control* IEEE, 2002, S. 215–220
- [112] KNOWLES, J.D. ; CORNE, D.W.: Approximating the nondominated front using the pareto archived evolution strategy. In: *Evolutionary computation* 8 (2000), Nr. 2, S. 149–172
- [113] KOKALJ, G. ; SCHATZ, P. ; EGGER, P. ; COMBÉ, T.: Herausforderungen und Chancen der Variantenkalibrierung bei Hybridfahrzeugen. In: *ATZextra* 17 (2012), Nr. 5, S. 26–31
- [114] KONAK, A. ; COIT, D. W. ; SMITH, A. E.: Multi-objective optimization using genetic algorithms: A tutorial. In: *Reliability Engineering & System Safety* 91 (2006), Nr. 9, S. 992–1007
- [115] KOOT, M. ; KESSELS, J. ; DE JAGER, B. ; HEEMELS, W. ; VAN DEN BOSCH, P. ; STEINBUCH, M.: Energy management strategies for vehicular electric power systems. In: *IEEE Transactions on Vehicular Technology* 54 (2005), Nr. 3, S. 771–782

- [116] KOZA, J.R.: *Genetic Programming, On the Programming of Computers by Means of Natural Selection*. MIT Press, Cambridge, MA, USA, 1992
- [117] KÜSELL, M. ; KRAFT, D.: Hybride Antriebsstränge in der Simulation. In: *ATZ-Automobiltechnische Zeitschrift* 108 (2006), Nr. 9, S. 704–710
- [118] KUTTER, S. ; BÄKER, B.: Predictive online control for hybrids: Resolving the conflict between global optimality, robustness and real-time capability. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)*. Lille, France, September 1–3, 2010
- [119] KUTTER, S. ; BÄKER, B. ; LANGHAMMER, S.: eVehicleLib-Eine Modelica-Bibliothek zur Simulation von Fahrzeugen mit alternativen Antrieben. In: *20th Symposium Simulationstechnik-ASIM*, 2009
- [120] LANGE, S.: Antriebsstrangsimulation – ein durchgängiger Ansatz vom Konzept bis zum Test. In: *AVL Energiemanagementworkshop HAW Ingolstadt*. Ingolstadt, Germany, Juni 2011
- [121] LANGFRITZ, P. ; MEYER, S. ; HINTZ, C.: Kalibrierprozesse auf dem Prüfstand. In: *ATZextra* 17 (2012), Nr. 5, S. 32–37
- [122] LEHNA, M.: Hybrid Fahrzeugkonzepte im Spannungsfeld zwischen technischen Möglichkeiten und Marktanforderungen. In: *15. Aachener Kolloquium Fahrzeug- und Motorentchnik*. Aachen, Germany, Oktober 9–11, 2006
- [123] LIEBL, J. ; FRICKENSTEIN, E. ; WIER, M. ; HAFKEMEYER, M. ; EL-DWAIK, F. ; HOCKGEIER, E.: Intelligente Generatorregelung - Ein Weg zur effizienten Dynamik. In: *ATZelektronik* (2006), Nr. 4
- [124] LINDEMANN, M ; GÜHMANN, C: VeLoDyn-Ein Werkzeug zur Triebstrangsimulation von Kraftfahrzeugen. In: *1. Tagung Simulation und Test in der Funktions- und Softwareentwicklung für die Automobilelektronik* (2003)
- [125] LINDEMANN, M. ; WOLTER, T.-M. ; FREIMANN, R. ; FENGLER, S.: Konfiguration von Hybridantriebssträngen mittels Simulation. In: *ATZ-Automobiltechnische Zeitschrift* 111 (2009), Nr. 5, S. 332–338
- [126] MARKEL, T. ; BROOKER, A. ; HENDRICKS, T. ; JOHNSON, V. ; KELLY, K. ; KRAMER, B. ; O’KEEFE, M. ; SPRIK, S. ; WIPKE, K.: ADVISOR: a systems



- analysis tool for advanced vehicle modeling. In: *Journal of Power Sources* 110 (2002), Nr. 2, S. 255–266
- [127] MIETTINEN, K.: *Nonlinear multiobjective optimization*. Bd. 12. Springer, 1999
- [128] MITSCHKE, M. ; WALLENTOWITZ, H.: *Dynamik der Kraftfahrzeuge*. Springer Verlag, 2004
- [129] MOLYNEAUX, A. ; LEYLAND, G. ; FAVRAT, D.: Multi-objective optimisation of vehicle drivetrains. In: *Proceedings of the 3rd Swiss Transport Research Conference, Ascona, Switzerland*, 2003
- [130] MONTAZERI, M. ; POURSAMAD, A. ; GHALICHI, B.: Application of genetic algorithm for optimization of control strategy in parallel hybrid electric vehicles. In: *Journal of the Franklin Institute* 343 (2006), Nr. 4, S. 420–435
- [131] MORENO, J. ; ORTÚZAR, M.E. ; DIXON, J.W.: Energy-management system for a hybrid electric vehicle, using ultracapacitors and neural networks. In: *IEEE Transactions on Industrial Electronics* 53 (2006), Nr. 2, S. 614–623
- [132] MUSARDO, C. ; RIZZONI, G. ; STACCIA, B.: A-ECMS: An adaptive algorithm for hybrid electric vehicle energy management. Seville, Spain, Dezember 12–15 2005, S. 1816–1823
- [133] NAGARAJ, S.C. ; DETRICK, B.: HIL and RCP tools for embedded controller development in hybrid vehicles. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC) IEEE*, 2009, S. 896–902
- [134] NAUNIN, D.: *Hybrid-, Batterie- und Brennstoffzellen-Elektrofahrzeuge: Technik, Strukturen und Entwicklungen*. Bd. 255. expert verlag, 2007
- [135] NAZRI, G.A. ; PISTOIA, G.: *Lithium batteries: science and technology*. Springer, 2003
- [136] NEUDORFER, H.: *Weiterentwicklung von elektrischen Antriebssystemen für Elektro- und Hybridstraßenfahrzeuge*. Österreichischer Verband für Elektrotechnik, 2010
- [137] NEUMANN, L. ; SALCHER, T. ; SCHINDLER, M.: *Verfahren zur Ermittlung einer Lastpunktverschiebung für einen Verbrennungsmotor eines Hybridfahrzeugs*. September 2011. – Offenlegungsschrift DE 10 2010 009 565 A1

- [138] NOREIKAT, K.E.: Antriebstechnik, die die Welt (nicht) braucht. In: *VDI-Berichte „Innovative Fahrzeugantriebe“* (2002), Nr. 1704, S. 143–160
- [139] PAPAGEORGIOU, M.: *Optimierung: Statische, dynamische, stochastische Verfahren für die Anwendung*. München : Oldenbourg, 1991
- [140] PARETO, V.: *Cours d'économie politique*. Lausanne : F. Rouge, 1896-1897
- [141] PISCHINGER, R. ; KLELL, M. ; SAMS, T.: *Thermodynamik der Verbrennungskraftmaschine*. Springer, 2009
- [142] PISU, P. ; KOPRUBASI, K. ; RIZZONI, G.: Energy management and drivability control problems for hybrid electric vehicles. In: *4th IEEE Conference on Decision and Control, European Control Conference (CDC-ECC)* IEEE, 2005, S. 1824–1830
- [143] POWERSIM: *Homepage*. Website. URL:<http://www.powersimtech.com/>. – (letzter Abruf am 30.01.2012)
- [144] RABENSTEIN, F. ; KLÜTING, M. ; KESSLER, F. ; KRETSCHMER, J. ; GRIEBEL, C.O. ; HOCKGEIGER, E.: The Full-Hybrid Powertrain of the new BMW ActiveHybrid 5. In: *20. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 8–10, 2011
- [145] RADCLIFFE, N.J.: The algebra of genetic algorithms. In: *Annals of Mathematics and Artificial Intelligence* 10 (1994), Nr. 4, S. 339–384
- [146] RAT DER EUROPÄISCHEN GEMEINSCHAFTEN: *Richtlinie 70/220/EWG des Rates vom 20. März 1970 zur Angleichung der Rechtsvorschriften der Mitgliedstaaten über Maßnahmen gegen die Verunreinigung der Luft durch Emissionen von Kraftfahrzeugen*.
- [147] RAUSCH, A. ; HÖHN, R. ; BROY, M. ; BERGNER, K. ; HÖPPNER, S.: *Das V-Modell XT: Grundlagen, Methodik und Anwendungen*. Springer, 2008
- [148] RECHENBERG, I.: *Evolutionstrategie–Optimierung technischer Systeme nach Prinzipien der biologischen Evolution*. Frommann-Holzboog, 1973
- [149] REIF, K.: *Konventioneller Antriebsstrang und Hybridantriebe: Mit Brennstoffzellen und alternativen Kraftstoffen*. Vieweg+Teubner, 2010

- [150] REYES-SIERRA, M. ; COELLO, C.A.C.: Multi-objective particle swarm optimizers: A survey of the state-of-the-art. In: *International Journal of Computational Intelligence Research* 2 (2006), Nr. 3, S. 287–308
- [151] RIEMER, T. ; MAUK, T. ; REUSS, H.-C.: Bestimmung des Einsparpotentials eines Parallelhybridantriebes unter Nutzung von Vorausschauinformationen. In: *8. Internationales Stuttgarter Symposium Automobil- und Motorentechnik*. Stuttgart, Germany, März 11–12, 2008
- [152] ROBERT BOSCH GMBH (HRSG.): *Autoelektrik/Autoelektronik-Systeme und Komponenten*. Fried. Vieweg und Sohn Verlag/GWV Fachverlage GmbH, 2007
- [153] ROLAND BERGER STRATEGY CONSULTANTS: *Study: E-Mobility - a promising field for the future*. 2011
- [154] RÜCKERT, J. ; BROSS, M.: Calibration methods at BMW – advantageous in many ways, not least economically. In: *Proc. of the 3rd International Symposium on Development Methodology*. Wiesbaden, Germany, November 10–11, 2009, S. 273–288
- [155] RUDOLPH, G.: Evolutionary search for minimal elements in partially ordered finite sets. In: *Evolutionary Programming VII* Springer, 1998, S. 345–353
- [156] RÜHL, M.: Der Antriebsstrang der Zukunft – Eine Trendaussage. In: *Fachtagung Klima schützen – Werte schaffen*. München, Germany, Mai 2011
- [157] SAE INTERNATIONAL: *SAE Standard J1711 - Recommended Practice for Measuring the Exhaust Emissions and Fuel Economy of Hybrid-Electric Vehicles, Including Plug-In Hybrid Vehicles*. 2010
- [158] SAGA, K.: Notwendige Fortschritte in der Antriebsstrangentwicklung zur nachhaltigen Mobilität mit Hybridtechnologie. In: *16. Aachener Kolloquium Fahrzeug- und Motorentechnik*. Aachen, Germany, Oktober 8–10, 2007
- [159] SALCHER, T. ; NEUMANN, L. ; KRAMER, G. ; HERZOG, H.-G.: Fuel-efficient state of charge control in hybrid electric vehicles. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)*. Lille, France, September 1–3, 2010
- [160] SALMAN, M. ; CHANG, M.F. ; CHEN, J.S.: Predictive energy management strategies for hybrid vehicles. In: *IEEE Vehicle Power and Propulsion Conference*. Chicago, IL, September 7–9 2005

- [161] SCHÄUFFELE, J. ; ZURAWKA, T.: *Automotive Software Engineering*. Vieweg+Teubner, 2010
- [162] SCHELS, A.: *Effizienzsteigerung des Ladezustandsmanagements hybrider Antriebe am Antriebsprüfstand*, Hochschule München, Diplomarbeit, 2011
- [163] SCHICK, B.: Energiemanagement within virtual test driving. In: *AVL Energiemanagementworkshop HAW Ingolstadt*. Ingolstadt, Germany, Juni 2011
- [164] SCHLÜTER, W. ; MAYER, C.: Model- und Hardware-in-the-Loop Test Systems for Hybrid Powertrain Development. In: *5. Braunschweiger Symposium: Hybridfahrzeuge und Energiemanagement*. Braunschweig, Germany, Februar 20–21, 2008
- [165] SCHMIDT, A. ; STEGMAIER, N. ; PIEGSA, A. ; REUSS, H.-C.: Anbindung des Antriebsstrangprüfstands an den Fahrsimulator zur energetischen Untersuchung von Hybrid-Antriebssträngen. In: *VDI-Berichte „Erprobung und Simulation in der Fahrzeugentwicklung“* (2010), Nr. 2106
- [166] SCHNEEWEISS, B. ; TEINER, P.: Hardware-in-the-Loop-Simulation am Motorenprüfstand für realitätsnahe Emissions- und Verbrauchsanalysen. In: *ATZextra* (2010), Mai, S. 76–79
- [167] SCHRÖPPEL, W.: *Energie - die Herausforderung des 21. Jahrhunderts*. Webseite. URL:[http://www.hss.de/fileadmin/media/downloads/Berichte/090911\\_Rede\\_Schr%C3%B6ppel.pdf](http://www.hss.de/fileadmin/media/downloads/Berichte/090911_Rede_Schr%C3%B6ppel.pdf). Version: September 2009. – (letzter Abruf am 30.01.2012)
- [168] SCHULZE, T. ; SCHULTE, T. ; SAUER, J.: Hybrid Drivetrain Simulation for Hardware-in-the-Loop Applications. In: *10. Internationales Stuttgarter Symposium Automobil- und Motorentechnik*. Stuttgart, Germany, März 16–17, 2010
- [169] SCHWEFEL, H.P.: *Evolutionstrategie und numerische Optimierung*, Technische Universität Berlin, Diss., 1975
- [170] SCIARRETTA, A. ; BACK, M. ; GUZZELLA, L.: Optimal control of parallel hybrid electric vehicles. In: *IEEE Transactions on Control Systems Technology* 12 (2004), Nr. 3, S. 352–363
- [171] SCIARRETTA, A. ; GUZZELLA, L.: Control of hybrid electric vehicles. In: *Control Systems Magazine, IEEE* 27 (2007), Nr. 2, S. 60–70

- [172] SCIARRETTA, A. ; GUZZELLA, L. ; ONDER, C.H.: On the power split control of parallel hybrid vehicles: from global optimization towards real-time control. In: *Automatisierungstechnik* 51 (2003), Nr. 5, S. 195–203
- [173] SEIFFERT, U. ; RAINER, G.: *Virtuelle Produktentstehung für Fahrzeug und Antrieb im KFZ: Prozesse, Komponenten, Beispiele aus der Praxis*. Springer, 2008
- [174] SERRAO, L.: *A comparative analysis of energy management strategies for hybrid electric vehicles*, The Ohio State University, Diss., 2009
- [175] SESHADRI, A.: *NSGA-II: A multi-objective optimization algorithm*. Website. URL:<http://www.mathworks.com/matlabcentral/fileexchange/10429-nsga-ii-a-multi-objective-optimization-algorithm>. – (letzter Abruf am 30.01.2011)
- [176] SIMIC, D. ; NOLL, M. ; PIRKER, F.: Innovative Entwicklungstools zur effizienten Auslegung von Hybrid- und Elektrofahrzeugen. In: *e & i Elektrotechnik und Informationstechnik* 125 (2008), S. 377–381. – ISSN 0932–383X
- [177] SITTI, A. ; HILDEBRANDT, C.: Optimierung der Betriebsstrategie von Hybridfahrzeugen im Serienentwicklungsprozess durch Kombination von Antriebsprüfstand und PC-Simulation. In: *5. IAV-Tagung: Simulation und Test für die Automobilelektronik*. Berlin, Germany, Mai 10–11, 2012
- [178] SITTI, A. ; MUMELTER, G. ; RABENSTEIN, F.: Development and calibration of hybrid electric vehicle operating strategies using simulations and a hybrid power train test bench. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)*. Chicago, IL, USA, September 6–9, 2011
- [179] SITTI, A. ; SALCHER, T. ; HERZOG, H.-G.: Optimierung des Ladezustandsmanagements in der Hybridserienentwicklung am Antriebsprüfstand. In: *VDI-Berichte „AUTOREG 2011 - Steuerung und Regelung von Fahrzeugen und Motoren“* (2011), Nr. 2135
- [180] SOLTIS, A. ; CHEN, X.: A new control strategy for hybrid electric vehicles. In: *Proceedings of the 2003 American Control Conference* Bd. 2. Denver, CO, 2003, S. 1398–1403
- [181] SRINIVAS, N. ; DEB, K.: Multiobjective optimization using nondominated sorting in genetic algorithms. In: *Evolutionary computation* 2 (1994), Nr. 3, S. 221–248

- [182] STEINHAUSER, K. ; BAUER, G.: Hitech im Antriebsstrang: Vernetzte Funktionen und Entwicklung. In: *Hanser Automotive* 10 (2007), S. 28–32
- [183] SUNDSTRÖM, O.: *Optimal control and design of hybrid-electric vehicles*, Eidgenössische Technische Hochschule ETH Zürich, Nr. 18543, 2009, Diss., 2009
- [184] TAN, K.C. ; LEE, T.H. ; KHOR, E.F.: Evolutionary algorithms for multi-objective optimization: performance assessments and comparisons. In: *Artificial intelligence review* 17 (2002), Nr. 4, S. 251–290
- [185] THE MATHWORKS: *Homepage*. Website. URL:<http://www.mathworks.com/>. – (letzter Abruf am 30.01.2012)
- [186] THE MODELICA ASSOCIATION MODELICA: *Homepage*. Website. URL:<http://www.modelica.org/>. – (letzter Abruf am 30.01.2012)
- [187] TÖPLER, F.: Optimierung von Hybridbetriebsstrategien mit elektronischem Horizont. In: *VDE-Kongress 2010 - E-Mobility* VDE VERLAG GmbH, 2010
- [188] TSCHÖKE, H.: Informationsreihe MTZ Wissen Die Elektrifizierung des Antriebsstrangs. In: *MTZ-Motortechnische Zeitschrift* 73 (2012), Nr. 5, S. 413–419
- [189] UNITED NATIONS: *ECE Regulation No. 101, Supplement 8*. 2009
- [190] UNITED STATES ENVIRONMENTAL PROTECTION AGENCY (EPA): *Title 40 of the Code of Federal Regulations (CFR), Part 86*
- [191] VAN BASSHUYSEN, R. ; SCHÄFER, F.: *Handbuch Verbrennungsmotor*. 2007
- [192] VAN VELDHUIZEN, D.A.: *Multiobjective evolutionary algorithms: classifications, analyses, and new innovations*, Department of Electrical and Computer Engineering. Graduate School of Engineering. Air Force Institute of Technology Wright Patterson AFB, OH, USA, Diss., 1999
- [193] VAN VELDHUIZEN, D.A. ; LAMONT, G.B.: Multiobjective evolutionary algorithms: Analyzing the state-of-the-art. In: *Evolutionary computation* 8 (2000), Nr. 2, S. 125–147
- [194] VAN VELDHUIZEN, D.A. ; LAMONT, G.B.: On measuring multiobjective evolutionary algorithm performance. In: *Evolutionary Computation, 2000. Proceedings of the 2000 Congress on* Bd. 1 IEEE, 2000, S. 204–211

- [195] VOLRATH, O. ; ARMSTRONG, N. ; LAMM, A. ; BITSCHKE, O. ; SCHENK, J.: Die Hybridlösung von Mercedes-Benz in der S-Klasse. In: *ATZ-Automobiltechnische Zeitschrift* 111 (2009), Nr. 5, S. 322
- [196] VON GRUNDHERR, J.: *Ableitung einer heuristischen Betriebsstrategie für ein Hybridfahrzeug aus einer Online-Optimierung*, Lehrstuhl für Verbrennungskraftmaschinen, Technische Universität München, Diss., 2010
- [197] WAGNER, G. ; NAUNHEIMER, H. ; SCHERER, H. ; DICK, A.: Achtgang-Automatikgetriebe zur Reduzierung des Kraftstoffverbrauchs. In: *ATZ-Automobiltechnische Zeitschrift* 109 (2007), Nr. 6
- [198] WAIDHAS, M.: Grundlegende Technologie von Doppelschichtkondensatoren. In: *ZVEI-Workshop/Frankfurt am Main* (2004)
- [199] WALLENTOWITZ, H. ; FREIALDENHOVEN, A.: *Strategien zur Elektrifizierung des Antriebsstranges: Technologien, Märkte und Implikationen*. Vieweg+Teubner Verlag, 2010
- [200] WALLENTOWITZ, H. ; JOHANNABER, M. ; SCHÜSSLER, M.: Hybrid-Elektro-Antriebssysteme, eine Übersicht. In: *DGES-Tagung Hybridtechnologien im Aufschwung, Deutsche Gesellschaft für elektrische Straßenfahrzeuge, Ford Forschungszentrum Aachen* (2003)
- [201] WEICKER, K.: *Evolutionäre Algorithmen*. Vieweg+ Teubner Verlag, 2007
- [202] WEISE, T.: *Global Optimization Algorithms – Theory and Application*. it-weise.de (self-published): Germany, 2009 <http://www.it-weise.de/projects/book.pdf>
- [203] WILDE, A.: *Eine modulare Funktionsarchitektur für adaptives und vorausschauendes Energiemanagement in Hybridfahrzeugen*, Fachgebiet für Energiewandlungstechnik, Technische Universität München, Diss., 2009
- [204] WILDE, A. ; SCHNEIDER, J. ; HERZOG, H.-G.: Fahrstil- und fahrsituationsabhängige Ladestrategie bei Hybridfahrzeugen. In: *ATZ-Automobiltechnische Zeitschrift* 110 (2008), Nr. 5, S. 412–421
- [205] WINKLER, D. ; GÜHMANN, C.: Hardware-in-the-Loop simulation of a hybrid electric vehicle using Modelica/Dymola. In: *Proceedings of the 22nd International Battery, Hybrid and Fuel Cell Electric Vehicle Symposium (EVS-22)*. Yokohama, Japan : Japan Automobile Research Institute, 2006, S. 1054–1063

- [206] WOLPERT, D.H. ; MACREADY, W.G.: No free lunch theorems for optimization. In: *Evolutionary Computation, IEEE Transactions on* 1 (1997), Nr. 1, S. 67–82
- [207] WON, J.S. ; LANGARI, R.: Intelligent energy management agent for a parallel hybrid vehicle-part II: torque distribution, charge sustenance strategies, and performance results. In: *IEEE Transactions on Vehicular Technology* 54 (2005), Nr. 3, S. 935–953
- [208] WU, J. ; DUFOUR, C. ; SUN, L.: Hardware-in-the-Loop Testing of Hybrid Vehicle Motor Drives at Ford Motor Company. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC)*. Lille, France, September 1–3, 2010
- [209] ZACH, C. ; SCHATZ, P. ; KOKALJ, G. ; KEUTH, N. ; COMBÉ, T.: Modellbasierte Optimierung der Betriebsstrategie hybrider Antriebe. In: *Proceedings of the 4th International Symposium on Development Methodology*. Wiesbaden, Germany, 2011, S. 49–61
- [210] ZHANG, B. ; CHEN, Z. ; MI, C. ; MURPHEY, Y.L.: Multi-objective parameter optimization of a series hybrid electric vehicle using evolutionary algorithms. In: *Proc. IEEE Vehicle Power and Propulsion Conference (VPPC) IEEE*, 2009, S. 921–925
- [211] ZHANG, L. ; BROWN, T. ; SAMUELSEN, G.S.: Fuel reduction and electricity consumption impact of different charging scenarios for plug-in hybrid electric vehicles. In: *Journal of power sources* 196 (2011), Nr. 15, S. 6559–6566
- [212] ZHANG, X. ; MI, C.: HEV Component Design and Optimization for Fuel Economy. In: *Vehicle Power Management* (2011), S. 287–301
- [213] ZHU, Y. ; CHEN, Y. ; TIAN, G. ; WU, H. ; CHEN, Q.: A four-step method to design an energy management strategy for hybrid vehicles. In: *Proceedings of the 2004 American Control Conference* Bd. 1. Boston, MA, 2004, S. 156–161
- [214] ZHU, Y. ; CHEN, Y. ; WU, Z. ; WANG, A.: Optimisation design of an energy management strategy for hybrid vehicles. In: *International Journal of Alternative Propulsion* 1 (2006), Nr. 1, S. 47–62
- [215] ZIMMER, I.: *Optimierung des verbrennungsmotorischen Zustarts im Hybridbetrieb*, Brandenburgische Technische Universität Cottbus, Diplomarbeit, 2011



- [216] ZITZLER, E. ; DEB, K. ; THIELE, L.: Comparison of multiobjective evolutionary algorithms: Empirical results. In: *Evolutionary computation* 8 (2000), Nr. 2, S. 173–195
- [217] ZITZLER, E. ; THIELE, L.: Multiobjective evolutionary algorithms: A comparative case study and the strength pareto approach. In: *Evolutionary Computation, IEEE Transactions on* 3 (1999), Nr. 4, S. 257–271
- [218] ZITZLER, E. ; THIELE, L. ; LAUMANN, M. ; FONSECA, C.M. ; FONSECA, V.G. da: Performance assessment of multiobjective optimizers: An analysis and review. In: *IEEE Transactions on Evolutionary Computation* 7 (2003), Nr. 2, S. 117–132

