

Simulative Auslegung optimierter Hybridantriebsstränge

Ralf Kleisch, Prof. Michael Bargende (IFS)
Dr. Felix Günther (Robert Bosch GmbH)

Institut für Fahrzeugtechnik Stuttgart (IFS)
Fahrzeugantriebe

Pfaffenwaldring 12
70569 Stuttgart

ralf.kleisch@ifs.uni-stuttgart.de
Felix.Guenther@de.bosch.com

Abstract: Zukünftige Abgasgesetzgebungen erfordern den Einsatz effizienter Hybridisierung im Antriebsstrang. Durch den Einsatz von Elektromotoren und Batterien im konventionellen Antriebsstrang ergibt sich die Frage nach der optimalen Dimensionierung der Komponenten, sowie dem optimalen Betrieb des Antriebsstrangs, zur Erreichung der vorgeschriebenen Abgasgrenzwerte. Da eine gesonderte Betrachtung der einzelnen Komponenten meist nur ein lokales Optimum identifiziert und eine kombinierte Betrachtung sehr rechenintensiv sein kann, wird in diesem Paper ein „Design of Experiments“ -basierter Ansatz verfolgt. Mit Hilfe der statistischen Versuchsplanung sollen die Komponenten-Kombinationen ganzheitlich betrachtet und die optimalen Konfigurationen bestimmt werden.

1 Einleitung

Zur Erreichung der zukünftigen Abgasgrenzwerte und CO₂-Emissionen scheint die Hybridisierung des konventionellen Antriebsstrang unumgänglich zu sein. Der Einsatz von Elektromotoren und Batterien im Fahrzeug führt zu neuen Betriebsweisen des Fahrzeugs. Unter anderem kann der Einsatz von Elektromotoren im Antriebsstrang eine rein elektrische Fahrt, die lokal emissionsfrei bewerkstelligt werden kann, ermöglichen. Ein weiterer wichtiger Vorteil ist die Nutzung der Bremsenergie in Form von Rekuperationsenergie. So ist es möglich, zuvor eingesetzte Antriebsenergie teilweise zu rekuperieren. Weiterhin ist es möglich, den Verbrennungsmotor durch Lastpunktanhebung oder -absenkung in effizienteren Wirkungsgradbereichen oder um häufige Drehmomentensprünge zu unterbinden.

Neben der Art und Weise wie das Fahrzeug betrieben wird, stellt sich auch die Frage der Auslegung und Dimensionierung der einzelnen Komponenten. Da die Betriebsweise des Fahrzeugs jedoch stark abhängig von den eingesetzten Antriebsaggregaten und der gewählten Topologie ist, ist eine isolierte Betrachtung bei der Bestimmung der effizientesten Antriebsstrangkonfiguration nur bedingt zielführend.

Um die beiden Fragestellungen in Kombination betrachten zu können, wird im Folgenden ein auf der statistischen Versuchsplanung basierender Ansatz verfolgt.

2 Betriebsstrategien

Neben der Auslegung ist auch die Betriebsweise des Antriebsstrangs ein wichtiger Bestandteil einer möglichen Effizienzsteigerung durch die Hybridisierung. Um verschiedene Komponenten-Dimensionierungen miteinander bewerten zu können, muss sichergestellt werden, dass diese auch ihren spezifischen Eigenschaften entsprechend optimal im Gesamtsystem betrieben werden.

Hierzu werden zum einen die Dynamische Programmierung und die „Equivalent Consumption Minimization Strategy“ eingesetzt. Die im Folgenden dargestellten Ergebnisse und Berechnungen wurden unter der Bedingung der Ladungsgerhaltung ausgeführt. D.h. der SoC¹ der Batterie bei Beendigung des Zyklus entspricht dem SoC beim Start des Zyklus.

2.1 Dynamische Programmierung

Die dynamische Programmierung ist in der Lage, unter zur Hilfenahme des Optimalitätsprinzips nach Bellman das globale Optimum zu ermitteln [1]. Da diese aufgrund der Anzahl der durchzuführenden Rechenoperationen sehr rechenintensiv ist, wird sie meist mit einer nur groben Diskretisierung gerechnet. Mit Hilfe einer „cost-to-go“ Matrix wird das Optimierungsproblem zunächst rückwärts durchlaufen und der optimale Weg identifiziert. Dabei werden zur Reduzierung der Anzahl an Rechenoperationen lediglich der günstigste Weg zum Erreichen eines jeweiligen Zeitschritts gespeichert. Pro Knoten wird lediglich der kostengünstigste Weg zu diesem jeweiligen Knoten berechnet. Dies ermöglicht das Auffinden eines globalen Optimums unter deutlich reduziertem Rechenaufwand. [2]

¹ SoC – “State of Charge”: Ladezustand der Batterie

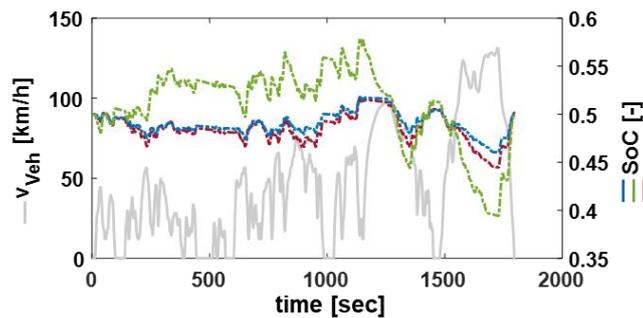


Abbildung 1: SoC-Verläufe für verschiedene Batteriekapazitäten im WLTC für einen P2-Hybriden

2.2 Equivalent Consumption Minimization Strategy

Bei der Equivalent Consumption Minimization Strategy handelt es sich um eine heuristische Methode zur Optimierung. Das globale Optimierungsproblem wird dabei in lokale Probleme umformuliert und pro Zeitschritt gelöst. Die Batterie wird als Energiepuffer betrachtet, der bei einer Entnahme elektrischer Energie zu einem späteren Zeitpunkt durch eine höhere Leistung am Verbrennungsmotor kompensiert werden muss. Die elektrische Energie wird über den sogenannten „s-Wert“ mit der eingesetzten Kraftstoffenergie in Relation gesetzt und zu einem Äquivalenzverbrauch aufsummiert.

$$\dot{m}_{f,eqv}(t) = \dot{m}_f(M_{VM}, n_{VM}, t) + \frac{s(SoC, t)}{Q_{lhv}} \cdot P_{batt}(M_{EM}, n_{EM}, SoC, t) \quad (\text{Gl. 1})$$

$\dot{m}_{f,eqv}$	Äquivalenzverbrauch
\dot{m}_f	Kraftstoffmassenstrom
s	Äquivalenzfaktor
Q_{lhv}	Unterer Heizwert
P_{batt}	Batterieleistung
SOC	Ladezustand der Batterie
M	Drehmoment
n	Drehzahl
t	Zeit

3 Statistische Versuchsplanung in der Antriebsstrangsimulation

Soll für einen gegebenen Antriebsstrang eine optimale EM-Leistung identifiziert werden, kann die maximale E-Maschinen-Leistung durch eine Skalierung der EM und deren Kennfeld simulativ bestimmt werden. Für gegebene Batteriekapazitäten ergeben sich die in Abbildung 2 dargestellten CO₂-Emissionen. Bereits mit einer geringen Anzahl an Konfigurationen mit verschiedenen EM-Leistungen, tritt ein deutliches Optimum bezüglich der CO₂-Emissionen auf.

Soll neben der E-Maschine auch eine Lithium-Ionen Batterie für den Einsatz im hybriden Antriebsstrang dimensioniert werden, ergeben sich jedoch sowohl bezüglich der erzielbaren CO₂-Emissionen, als auch bezüglich der optimalen E-Maschinenleistung, abweichende Optima. Am Beispiel der Variation der Batteriekapazität in Abbildung 2, ergeben sich für eine Batteriekapazität von 0,5 kWh – 4 kWh optimale E-Maschinen-Dimensionierungen zwischen 40 kW und 60 kW maximaler Leistung. Da eine voll- oder teilfaktorielle Untersuchung verschiedener Komponentenkombinationen sehr rechenintensiv sein kann, wird im Folgenden der Ansatz der statistischen Versuchsplanung untersucht. Die Idee der statistischen Versuchsplanung ist es, ein Systemverhalten mit Hilfe analytischer Modelle zu ermitteln und abzubilden und dadurch die Anzahl notwendiger Versuche zur Identifizierung des Systemverhaltens zu reduzieren.

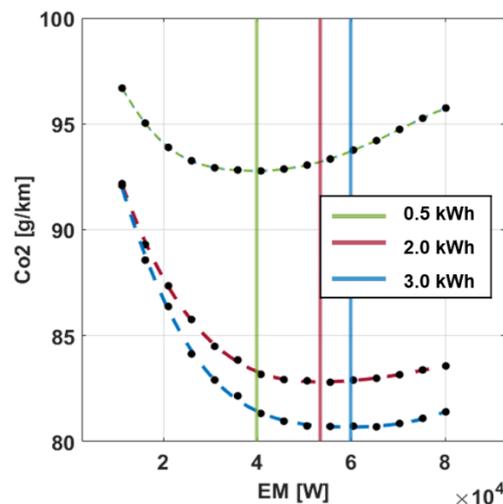


Abbildung 2: CO₂-Werte für eine Variation der maximalen E-Maschinenleistung bei verschiedene Batterie-Kapazitäten

In einem ersten Schritt der Versuchsplanung wird ein Testplan generiert. Hierzu werden zunächst die unabhängigen Variablen und der Bereich, in dem diese variiert werden sollen, definiert. Sowohl für die E-Maschine als auch die Batterie wurden diese Bereiche anhand bereits in Serie befindlicher Fahrzeuge grob orientiert und ausgeweitet, um auch das Verhalten in den Randbereichen bisheriger Konzepte zu untersuchen. Mit Hilfe verschiedener Methoden kann anschließend der Versuchsraum mit Versuchspunkten besetzt werden. Hierzu werden bei einem unbekanntem Systemverhalten meist raumfüllende Designs verwendet. Ein häufig eingesetztes Verfahren ist das Latin Hypercube Sampling. Dabei wird der zu untersuchende Parameterraum in eine definierte Anzahl an Intervallen geteilt und diese Intervalle mit jeweils einem Versuchspunkt per Zufall besetzt. Dies führt zu einer gleichmäßigen und vollständigen Abdeckung des Parameterraums. Ist das Systemverhalten bekannt oder abschätzbar, kann mit Hilfe D-optimaler Versuchspläne eine höhere Dichte an Versuchspunkten in die Randbereiche des Raumes gelegt werden. Soll ein unbekanntes Systemverhalten untersucht werden, können auch verschiedene Versuchspläne kombiniert werden. [3]

Das Vorgehen zum Einsatz der statistischen Versuchsplanung wird im Folgenden am Beispiel eines P2-Hybriden erläutert. Die E-Maschine wird hier parallel angeordnet und mit einer Trennkupplung vom Verbrennungsmotor abkoppelbar ausgeführt. Um eine effiziente P2-Konfiguration zu finden, werden die maximale Leistung der E-Maschine und die Batteriekapazität als unabhängige Variablen variiert. Die Basis-Konfiguration des Antriebsstrangs ist in Tabelle 1 dargestellt.

Tabelle 1 – Untersuchte P2-Hybrid-Konfiguration

HEV Topologie	Parallel-P2
Verbrennungsmotor	75 kW Otto-Motor
m_{Veh}	~ 1650 kg
Getriebe	7 Gang DCT
EM	11 kW – 90 kW
Batterie-Kapazität	0.5 – 4 kWh

Nach der Versuchsplanerstellung und der Simulation der erstellten Komponenten-Kombinationen, erfolgt ein Modell-Fitting. In Abbildung 3 sind die Ergebnisse der oben erwähnten Optimierung für eine Rückwärtssimulation in Verbindung mit der Dynamischen Programmierung dargestellt. Die Projektion der eingezeichneten Punkte auf die Grundebene stellen die simulierten Komponenten-Kombinationen dar. Auf der z-Achse sind die berechneten CO₂-Werte der jeweiligen Kombination aufgetragen.

Die in Abbildung 3 eingezeichnete Ebene bildet das erstellte Gauß-Prozess-Modell ab. Dabei handelt es sich um eine parameterfreie Methode zur Erstellung einer Regression zwischen Eingangs- und Ausgangsdaten, basierend auf einer Mittelwertfunktion und einer Kovarianzfunktion, die den Zusammenhang beliebiger Punkte im Eingangsraum beschreibt. [4] Der Gauß-Prozess ist ein Verfahren, das keine explizite Kenntnis über den genauen Zusammenhang zwischen den Eingangsvariablen und den Ausgangsvariablen voraussetzt und eignet sich somit gut für eine Automatisierung bzgl. verschiedener Parameter. Dennoch müssen die erstellten Modelle für eine weitergehende Analyse überprüft werden und deren Genauigkeit sichergestellt werden. Zur Bewertung der Modellgüte werden die Residuen oder auch die mittlere quadratische Approximation an Validierungspunkten, die nicht in die Metamodellerstellung eingegangen sind, ausgewertet. [5] Die Validierungspunkte sind in den folgenden Abbildungen als rote Dreiecke dargestellt

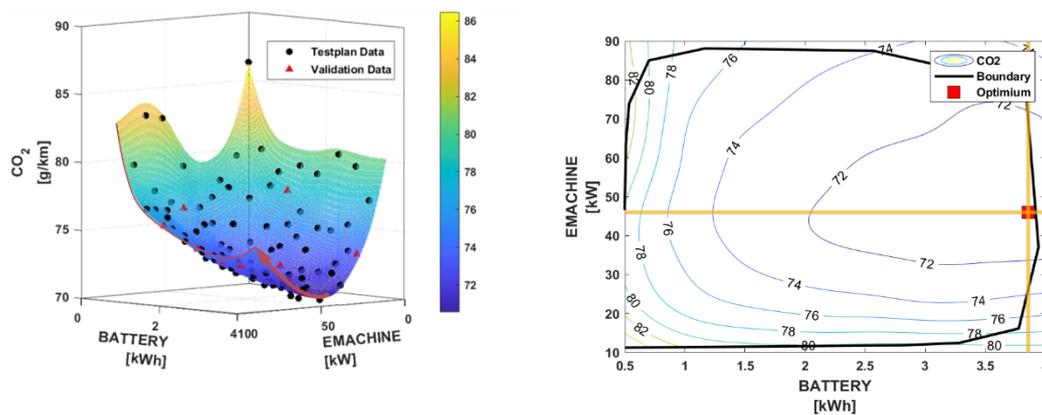


Abbildung 3: Darstellung des Gauß-Prozess-Modell für DP-optimierte CO₂-Emissionen

Es zeigt sich, dass die Modellgüte des Gauß-Prozesses für die DP-berechneten CO₂-Emissionen mit $R^2 = 0,998$ ein hohes Bestimmtheitsmaß annimmt.

$$R^2 = \frac{SSE}{SST} = \frac{\sum_{k=1}^K (\hat{y}_k - \bar{y}_k)^2}{\sum_{k=1}^K (y_k - \bar{y}_k)^2} \quad [6] \quad (\text{Gl. 2})$$

SSE „Total sum of squares“

SST „explained sum of squares“

k Versuchspunkte

\hat{y}_k Ermittelte Schätzwert

y_k Beobachtungswert

Die Wurzel der mittleren Fehlerquadrate (RMSE – „Root Mean Square Error“) für die Validierungspunkte weist mit $RMSE = 0.18$ eine sehr geringe Abweichung auf und bestätigt die Güte des Modells. Das erzeugte Modell bildet ein ähnliches Verhalten wie die in Abbildung 2 dargestellten Variationen ab. Es zeigt sich deutlich, dass die CO_2 -Emissionen mit steigender Batteriekapazität sinken. Jedoch bildet sich bezüglich der Batteriegröße kein konkretes Optimum aus. Für die verschiedenen Batteriekapazitäten zeigen sich klare Optima hinsichtlich der E-Maschinen-Dimensionierung. Das globale Optimum bzgl. beider Parameter liegt hier bei einer E-Maschinenleistung von 47 kW und einer Batteriekapazität von 4 kWh.

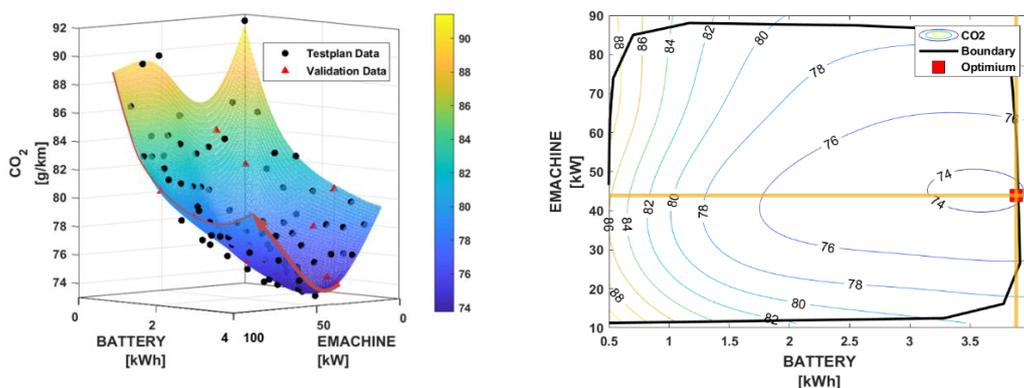


Abbildung 4: Darstellung des Gauß-Prozess-Modell für ECMS-optimierte CO_2 -Emissionen

Abbildung 4 stellt den identischen Versuchsplan wie Abbildung 3 dar. Dieser wurde jedoch mit einer detaillierteren Rückwärtssimulation in Verbindung mit einer ECMS als Betriebsstrategie berechnet. Es ist zu erkennen, dass die berechneten CO_2 -Emissionen erwartungsgemäß höher liegen. Es zeigt sich jedoch auch, dass die Simulationsergebnisse ein ähnliches Verhalten bzgl. der beiden variierten Komponenten aufweisen. Auch hier ist kein klares Optimum bzgl. der Batteriekapazität zu identifizieren, bzw. liegt dieses im Randbereich des Modells und kann eine Folge einer zu geringen Testanzahl in diesem Kennfeldbereich sein. Die Abhängigkeit der E-Maschinendimensionierung von der Batterieauslegung, die mit Hilfe der DP aufgezeigt wurde, bestätigt sich auch hier. Das Optimum der maximalen E-Maschinenleistung liegt hierbei mit 45 kW geringfügig niedriger.

Es ist zu erkennen, dass die Residuen durch die Berechnung mit der ECMS-Rückwärtssimulation mit einem $R^2 = 0.96$ geringfügig höher liegen, als die der DP-Simulation. Dies ist darauf zurückzuführen, dass die ECMS-Berechnung in diesem Beispiel mit einer einheitlichen Applikation des s-Wertes aus (Gl. 1) und weiterer Applikationswerte durchgeführt wurde.

Da bei der Auslegung eines Antriebsstrangs die Kosten eine wichtige Rolle spielen, wurden in den in Abbildung 5 dargestellten Modellen, die TCO für die jeweiligen Konfigurationen berechnet. Unter Einbeziehung der Kosten zeigt sich, dass sich ein deutliches globales Optimum bezüglich der Dimensionierung beider Komponenten ergibt. Das Optimum weist dabei eine Batteriekapazität von 1,5 kWh und eine E-Maschinenleistung von 43 kW aus. D.h. das Optimum der TCO²-Berechnung identifiziert eine ähnliche E-Maschinenkonfiguration, verschiebt jedoch die optimale Batteriekapazität deutlich in Richtung geringerer Kapazitäten.

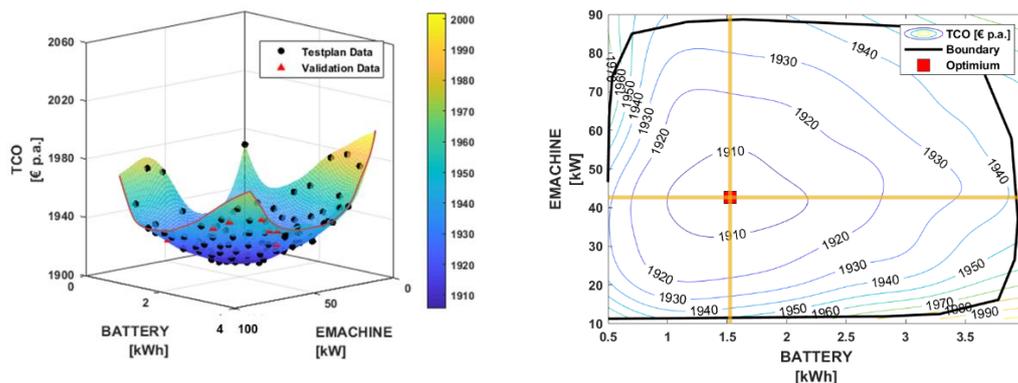


Abbildung 5: Darstellung des Gauß-Prozess-Modells für DP-optimierte TCO-Berechnung

Wird das TCO-optimale Konzept herangezogen, entstehen höhere CO₂-Emissionen von ca. 2,5 g/km.

Eine wichtige Rolle in der Berechnung und Optimierung einer Vielzahl von Hybrid-Konfigurationen spielt die Rechenzeit. Bei der Berechnung von DoEs ist diese proportional zu der Anzahl der Testpunkte. Weiterhin benötigt auch die Testplan-Erstellung, die Skalierung der Komponenten als auch die Erstellung der Modelle Rechenkapazität. Diese fällt jedoch im Vergleich mit der Simulationszeit gering aus.

Abbildung 6 zeigt verschiedene Modelle, die jeweils auf Basis von 60, 30 und 20 Testpunkten erstellt wurden. Als Vergleichsreferenz kann dabei nur ein Modell höherer Punktdichte dienen, da sich die grundlegenden Bewertungskriterien nur auf das jeweilige Modell beziehen. D.h. ein Modell mit zu geringer Testzahl kann beispielsweise ein hohes Bestimmtheitsmaß und geringe Residuen aufweisen und dennoch das Systemverhalten nicht korrekt abbilden. In Referenz zu den zuvor beschriebenen Modellen mit 100 Testpunkten, zeigt sich, dass auch eine Testanzahl von 60 Punkten in diesem Anwendungsfall eine hohe Übereinstimmung des Systemverhaltens aufweist und das globale Optimum dem des detaillierteren Plans entspricht.

² TCO: „Total Cost of Ownership“ - Gesamtbetriebskosten

Abbildung 6 in der Mitte zeigt einen Testplan mit 30 Punkten. Auch hier lässt sich erkennen, dass das grundsätzliche Verhalten zwischen Ausgangs- und Eingangsvariablen mit hoher Modellgüte abgebildet werden kann. Wird die Testzahl, wie im linken Teil der Abbildung weiter reduziert, ist zu erkennen, dass zum einen der vorgegebene Testraum zu großen Teilen nicht ausgefüllt werden kann und somit Unsicherheitsbereiche entstehen und zum anderen das Systemverhalten falsch abgebildet wird. Durch die geringe Besetzung der Testpunkte im Raum wird eine maximale E-Maschinenleistung von > 50 kW als Optimum ausgewiesen, während die anderen Varianten Leistungen von < 50 kW als Optimum identifizieren.

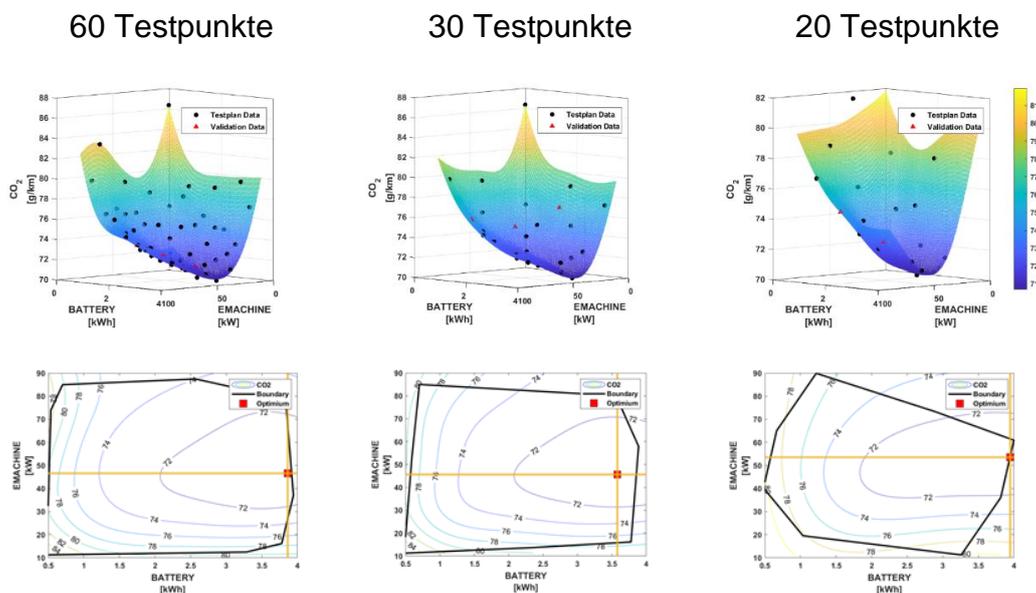


Abbildung 6: Vergleich der Metamodelle auf Basis variierender Testzahlen für DP-optimierte Berechnung

4 Zusammenfassung

Die statistische Versuchsplanung ist ein hilfreiches Mittel in der Hybrid-Antriebsstrangsimulation, um optimale Konzepte bzgl. verschiedener Fahransforderungen herauszuarbeiten. Die Erstellung von Metamodellen hilft dabei die Anzahl notwendiger Simulationsdurchgänge deutlich zu reduzieren und bildet das Systemverhalten mit hoher Güte ab. Um eine Vielzahl an Konzepten vergleichen zu können, ist es wichtig die Anzahl der Versuchspunkte so zu wählen, dass einerseits die Rechenzeit möglichst gering gehalten werden kann und andererseits dennoch eine ausreichende Güte der Metamodelle gewährleistet wird.

5 Literaturverzeichnis

- [1] R. Bellman, „Dynamic Programming,“ Princeton University Press, Princeton, 1957.
- [2] O. Sundstrom und L. Guzzella, „A Generic Dynamic Programming Matlab Function,“ 18th IEEE International Conference on Control Applications, 2009.
- [3] W. Kleppmann, Versuchsplanung - Produkte und Prozesse optimieren, Hanser, 2016.
- [4] D. Bergmann und K. Graichen, „Gaußprozessregression zur Modellierung zeitvarianter Systeme,“ 2019.
- [5] K. Siebertz, D. van Bebbler und T. Hochkirchen, Statistische Versuchsplanung - Design of Experiments (DoE), Springer-Verlag Berlin Heidelberg, 2010.
- [6] K. Backhaus, B. Erichson, W. Plinke und R. Webder, Multivariante Analysemethoden, Springer Berlin Heidelberg, 2018.