

Ermittlung optimaler Unterstützungsstrategien für E-Bikes unter Berücksichtigung der geplanten Route

Fahrer von Elektrofahrzeugen fürchten, während der Fahrt mit leerem Akku „liegen“ zu bleiben. Daher soll eine optimale Unterstützungssteuerung von E-Bikes ermittelt werden, mit dem Ziel eine Strecke ohne Unterschreitung der verfügbaren Akkukapazität schnellstmöglich zurückzulegen. Mithilfe des CMSC-Verfahrens werden optimale Steuerungsstrategien berechnet und die Lösungen im Modell und Fahrversuch validiert. Dabei wird ersichtlich, dass die optimierte Unterstützung Vorteile bietet.

1. Einleitung

Elektrofahrräder können derzeit ein starkes Marktwachstum sowie eine Zunahme der Popularität aufweisen. Zusätzlich kommt es durch den Klimawandel zu einer verstärkten Elektrifizierung der Mobilität. Davon profitiert das Elektrofahrzeug besonders in staugeplagten urbanen Regionen und als attraktive Art der Freizeitge-

staltung [1]–[7]. Eines der Hauptprobleme von Elektrofahrzeugen und der Elektromobilität im Allgemeinen ist die beschränkte Akkukapazität und die daraus resultierende limitierte Reichweite in Kombination mit einer langen Ladedauer [5]. Dies führt zur sogenannten „Reichweitenangst“ des Fahrers des Elektrofahrzeugs. Dabei handelt es sich um die Befürchtung, während der Fahrt aufgrund eines leeren Akkus

„liegen“ zu bleiben [8]. Lösungen zur Bekämpfung der Reichweitenangst bei Elektrofahrrädern stellen oftmals lediglich eine Verschiebung des Problems zu größeren Reichweiten dar. So kann beispielsweise durch Rekuperation eine gewisse Reichweitensteigerung erzielt werden [9], [10]. Alternativ können Akkus mit größerer Kapazität eingesetzt werden. Beides bringt wiederum Nachteile (Kosten, Gewicht, ...) mit sich und stellt keine nachhaltige Lösung des Problems der Reichweitenangst dar.

Zur Reduzierung der Reichweitenproblematik bei Elektrofahrrädern soll die optimale Unterstützungsstrategie ermittelt werden, die dem Fahrer ermöglicht, unter Einhaltung der beschränkten Akkukapazität eine geplante Strecke in minimaler Zeit zu absolvieren. Dafür wird ein Modell eines Elektrofahrrads erstellt (siehe Abschnitt 2), welches mithilfe eines Optimierungsalgorithmus untersucht wird (siehe Abschnitt 3). Die ermittelte Lösung wird sowohl im Modell als auch im Fahrversuch einem Vergleich zu herkömmlichen Fahrmodi unterzogen, um das erzielte Ergebnis der optimierten Strategie experimentell zu validieren (siehe Abschnitt 4). In einer Diskussion wird auf das Potenzial und die Umsetzbarkeit auf dem Elektrofahrrad zur automatisierten Unterstützungssteuerung eingegangen (siehe Abschnitt 5). Abschließend werden die Ergebnisse zusammengefasst und ein Ausblick zeigt zukünftige Forschungsfelder auf (siehe Abschnitt 6). Sämtliche Untersuchungen erfolgen anhand des Bosch eBike Systems.

2. Modellbildung

Betrachtet werden sogenannte Pedelecs (**Pedal Electric Cycles**), welche mit einer Kombination aus menschlicher und elektrischer Leistung angetrieben werden [3]. Aus diesem Grund wird auch von einem human-electric hybrid [11] gesprochen, einem mechanisch gekoppelten, parallelen Hybrid aus Mensch und elektrischer Maschine [12]. Ein ausschließlich elektrischer Betrieb ist gesetzlich bedingt nicht möglich [13]. Die Motorleistung P_{Motor} ergibt sich nach (1) aus der Fahrerleistung P_{Fahrer} sowie dem Unterstützungsfaktor x_{assist} . Eine alleinige Leistungseinbringung durch den Fahrer, wie bei einem herkömmlichen Fahrrad, ist weiterhin möglich ($x_{\text{assist}} = 0$). Die eingebrachte Antriebs-

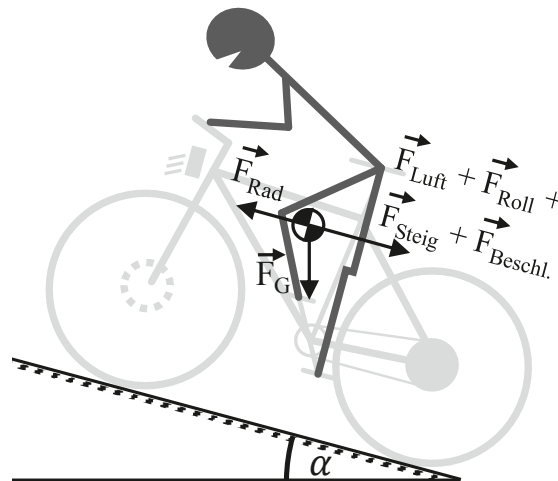


Bild 1: Fahrwiderstände am Elektrofahrrad (F_G : Gewichtskraft, α : Fahrbahnsteigung) [9].

leistung P_{System} ist die Kombination aus Fahrer- und Motorleistung (2).

$$P_{\text{Motor}} = P_{\text{Fahrer}} \cdot x_{\text{assist}} \quad (1)$$

$$P_{\text{System}} = P_{\text{Fahrer}} + P_{\text{Motor}} = P_{\text{Fahrer}} \cdot (1 + x_{\text{assist}}) \quad (2)$$

2.1 Beschreibung der Längsdynamik

Während der Fahrt des Elektrofahrrads muss je nach Fahrsituation eine Antriebsleistung am Hinterrad P_{Rad} aufgebracht werden. Diese entspricht der eingebrachten Systemleistung abzüglich der Wirkungsgradverluste im Antriebsstrang η_{Antrieb} (3). Die benötigte Antriebsleistung ergibt sich aus der Widerstandskraft F_{Wid} , als Summe aus Luft- F_{Luft} , Roll- F_{Roll} , Steigungs- F_{Steig} und Beschleunigungswiderstand $F_{\text{Beschl.}}$ (4). Diese wirkt der antreibenden Kraft F_{Rad} , die sich aus der eingebrachten Antriebsleistung am Hinterrad ergibt (5), entgegen. Bild 1 stellt diesen Zusammenhang für eine allgemeine Fahrsituation exemplarisch dar [14].

$$P_{\text{Rad}} = P_{\text{System}} \cdot \eta_{\text{Antrieb}} \quad (3)$$

$$F_{\text{Wid}} = F_{\text{Luft}} + F_{\text{Roll}} + F_{\text{Steig}} + F_{\text{Beschl.}} \quad (4)$$

$$F_{\text{Rad}} = P_{\text{Rad}} \cdot v_{\text{eBike}} \quad (5)$$

2.2 Beschreibung des Energieverbrauchs

Die Leistung der Batterie P_{Bat} ergibt sich aus der benötigten Motorleistung P_{Motor} unter Berücksichtigung der Wirkungsgrade des Motors η_{Motor} sowie des Kabels η_{Kabel} zwischen Motor und

Batterie (6). Daraus kann die der Batterie entnommene Energiemenge E_{Bat} berechnet werden (7).

$$P_{\text{Motor}} = P_{\text{Bat}} \cdot \eta_{\text{Kabel}} \cdot \eta_{\text{Motor}} \quad (6)$$

$$E_{\text{Bat}}(t) = \int_0^t P_{\text{Bat}}(\tau) d\tau \quad (7)$$

Die Bestimmung des Ladezustands der Batterie (SoC, engl. State of Charge) ist in der Praxis schwierig, da viele Einflussfaktoren, unter anderem die Temperatur und die durchlaufene Zyklenanzahl, eine Rolle spielen [15]. Aufgrund der Komplexität wird in der Praxis häufig von SoC-Schätzung gesprochen. Hierfür haben sich verschiedene Methoden etabliert [16], [17]. Für die SoC-Bestimmung am Elektrofahrrad kommt hier die Ladungsbilanzierung zum Einsatz. Es werden sämtliche ein- und ausgehenden Ströme der Batterie I_{Bat} integriert und dadurch die Veränderung der Ladungsmenge in der Batterie bilanziert. Mit bekannter verfügbarer Gesamtkapazität Q_{tot} und initialem Ladezustand SoC_0 kann der momentan vorliegende SoC ermittelt werden (8) [18].

$$\text{SoC}(t) = \text{SoC}_0 + \frac{1}{Q_{\text{tot}}} \cdot \int_0^t P_{\text{Bat}}(\tau) d\tau \quad (8)$$

2.3 DGL-System zur Optimierung

Mit den vorgestellten Gleichungen kann ein Differentialgleichungssystem (DGL-System) aufgestellt werden, welches das Elektrofahrrad hinsichtlich der Längsdynamik und des Energieverbrauchs für die Optimierung hinreichend genau beschreibt (9). Der Zustandsvektor ist $x = [x_1, x_2, x_3]^T = [s, v_{\text{eBike}}, Q]^T$ bzw. $\dot{x} = [\dot{x}_1, \dot{x}_2, \dot{x}_3]^T = [v_{\text{eBike}}, a_{\text{eBike}}, I_{\text{Bat}}]^T$ mit der zurückgelegten Strecke s , der Geschwindigkeit v_{eBike} , der Beschleunigung a_{eBike} sowie der Ladungsmenge Q und dem Batteriestrom I_{Bat} .

$$\dot{x} = \begin{bmatrix} v_{\text{eBike}} \\ \frac{P_{\text{System}} - F_{\text{Luft}} - F_{\text{Roll}} - F_{\text{Steig}}}{m_{\text{System}} + \frac{\Theta_{\text{Laufräder}}}{r_{\text{Rad}}^2}} \\ \frac{P_{\text{System}} \cdot x_{\text{assist}}}{\eta_{\text{Kabel}} \cdot \eta_{\text{Motor}} \cdot V_{\text{Bat}}} \end{bmatrix} \quad (9)$$

Die zweite Gleichung beschreibt die Längsdynamik und ist mithilfe des Beschleunigungswiderstands nach der Beschleunigung des Elektro-

fahrrads a_{eBike} aufgelöst (10). Hierbei werden die translatorische Trägheit aufgrund der Masse des Systems m_{System} , sowie die größten rotatorischen Trägheitsmomente der Laufräder $\Theta_{\text{Laufräder}}$, welche mithilfe des Radius r_{Rad} in eine translatorische Kraft konvertiert werden, mitberücksichtigt.

$$F_{\text{Beschl.}} = a_{\text{eBike}} \cdot \left(m_{\text{System}} + \frac{\Theta_{\text{Laufräder}}}{r_{\text{Rad}}^2} \right) \quad (10)$$

Die dritte Gleichung des DGL-Systems beschreibt den Energieverbrauch. Dabei wird zusätzlich die Batteriespannung V_{Bat} benötigt. Diese ist im Rahmen der Optimierung als konstant angesetzt. Mithilfe des DGL-Systems wird die Optimierung durchgeführt. Die Kalibrierung und Validierung des Modells ist in [19] näher beschrieben.

3. Optimierung

In diesem Abschnitt wird das Optimierungsproblem vorgestellt, bevor der verwendete Optimierungsalgorithmus sowie die erzielten Ergebnisse näher betrachtet werden.

3.1 Optimierungsproblem

Das Ziel der Optimierung ist es, Erkenntnisse hinsichtlich der optimalen Unterstützungssteuerung von Elektrofahrrädern im Modell zu erhalten und damit die Basis für eine mögliche Implementierung auf dem Elektrofahrrad zu generieren. Hierbei soll eine vorgegebene Strecke mit beschränkter Energiemenge des Akkus in möglichst kurzer Zeit zurückgelegt werden. Daraus ergibt sich mit dem in (9) beschriebenen DGL-System folgendes nichtlineares Optimierungsproblem

$$\begin{aligned} \min_{u(t)} \int_{t_0}^{t_f} 1 dt & \quad (11) \\ \text{s.t.: } \dot{x}(t) &= f(x(t), u(t)), \\ x_1(t_0) &= 0, \quad x_2(t_0) = v_0, \quad x_3(t_0) = Q_0, \\ x_1(t_f) &= s_f, \quad x_2(t_f) \geq 0, \quad x_3(t_f) = Q_f, \\ I_{\text{Bat}} - I_{\text{Bat,max}} &\leq 0, \\ 0 \leq s(t) \leq s_f, \quad 0 \leq v(t), \quad 0 \leq Q(t) \leq Q_f, \\ 0 \leq u(t) &\leq x_{\text{assist,max}}(v_{\text{eBike}}). \end{aligned}$$

Die Steuervariable u ist der Unterstützungsfaktor x_{assist} . Die Fahrerleistung P_{Fahrer} und die Steigung der Fahrbahn α dienen als Modelleingang.

Die Zustände zu Beginn der Fahrt (t_0) sind durch eine initiale Geschwindigkeit v_0 und einen initialen Ladezustand Q_0 definiert, die Position ist 0. Am Ende der Fahrt (t_f) muss die Endposition der Strecke s_f sowie der gewünschte Endladezustand Q_f erreicht sein, die Endgeschwindigkeit ist frei. Durch die Ungleichungsnebenbedingung ist der Strom der Batterie hinsichtlich eines Maximalwerts $I_{\text{Bat,max}}$ beschränkt. Die Steuerung darf einen geschwindigkeitsabhängigen Maximalwert $x_{\text{assist,max}}$, der vom System des Elektrofahrrads sowie dem Gesetzgeber vorgegeben ist (maximale Unterstützungsgeschwindigkeit $v_{\text{assist,max}} = 25 \text{ km/h}$), nicht überschreiten.

3.2 Optimierungsalgorithmus

Zur Lösung des Optimierungsproblems kommt eine Kombination aus zwei Verfahren, dem Mehrfachschießverfahren und der Kollokation (CMSC-Ansatz, engl. combined multiple shooting with collocation), zum Einsatz. Der CMSC-Ansatz löst das Optimalsteuerungsproblem mithilfe des Mehrfachschießverfahrens und berechnet die Differentialgleichungen, Gradienten und Sensitivitäten mithilfe der Kollokationsmethode [20], [21]. Die Kombination nutzt die Vorteile beider Verfahren und löst das Optimierungsproblem effizient und genau. Es kommt eine Softwarearchitektur des Instituts für Prozessoptimierung der Fakultät Informatik und Automatisierung der TU Ilmenau zum Einsatz [22], [23]. Die Lösung wird mithilfe des Ipopt-Solvers berechnet [24].

Um die Effizienz des verwendeten Verfahrens zu zeigen, wird ein Vergleich zwischen dem CMSC-Ansatz sowie der dynamischen Programmierung (DP) durchgeführt. Die DP wird zur Lösung von Optimalsteuerungsproblemen im Automobil- und Fahrradbereich eingesetzt, beispielsweise in [25]–[28]. Der DP-Ansatz wird mit einem Algorithmus des *Institute for Dyna-*

Tabelle 1: Rechenzeiten DP und CMSC

Verfahren	Streckenlänge / m	Diskretisierung / m	Rechenzeit / s
DP	2000	5	484
CMSC	2000	5	62

mic Systems and Control der ETH Zürich realisiert [29]. Das Optimierungsproblem wird mit beiden Verfahren auf derselben Strecke mit den gleichen Randbedingungen gelöst. Die Diskretisierung erfolgt über die Strecke in 5m-Schritten und nicht wie üblich über die Zeit. Der Grund hierfür liegt darin, dass die Modelleingänge P_{Fahrer} und α in Abhängigkeit der Strecke s vorliegen und die Zeit das Optimierungsziel darstellt. Die Lösungen sind identisch, jedoch kann mithilfe des CMSC-Verfahrens das Problem fast achtmal schneller gelöst werden als mithilfe des verwendeten DP-Ansatzes (siehe **Tabelle 1**). Dies bestätigt die Effizienz des CMSC-Verfahrens, welches im Weiteren verwendet wird.

Nun werden die Rechenzeit und das Konvergenzverhalten des CMSC-Verfahrens näher betrachtet, indem Strecken unterschiedlicher Länge berechnet und die Eingangsparameter P_{Fahrer} und α wahlweise konstant gehalten bzw. variiert werden. Eine Zusammenfassung der Ergebnisse gibt **Tabelle 2**. Hierbei handelt es sich lediglich um Trends, die mithilfe der hier durchgeführten empirischen Untersuchungen ermittelt wurden. Mit zunehmender Komplexität und Größe des Optimierungsproblems nimmt die Rechenzeit zu und das Konvergenzverhalten verschlechtert sich. Dieses Verhalten war zu erwarten. Jedoch ist der gewählte Optimierungsalgorithmus geeignet für die geplanten Analysen. Zur Ableitung der optimalen Fahrstrategie genügen Betrachtungen kurzer Strecken mit geringer zur Verfügung stehender Energiemenge, da die Ergebnisse auf längere Strecken übertragen werden können. Zusätzlich sollten

Tabelle 2: Übersicht über die Rechenzeiten und das Konvergenzverhalten des CMSC-Verfahrens

Streckenlänge s in km	Diskretisierung Δs in m	Fahrerleistung	Steigung	Rechenzeit in min	Konvergenzverhalten
< 2	5	Variabel	Konstant	< 1	Gut
< 2	5	Konstant	Variabel	< 1	Gut
< 2	5	Variabel	Variabel	< 5	Gut
≈ 10	20	Konstant	Variabel	≈ 15	Gut
≈ 10	20	Variabel	Variabel	> 15	Schlecht
≈ 25	20	Konstant	Variabel	> 30	Schlecht




Bild 2: Optimale Steuerung einer realen, geglätteten Strecke.

die Eingangsparameter getrennt voneinander variiert werden, um den Einfluss dieser besser analysieren zu können. Unter Berücksichtigung dieser Aspekte zeigt sich, dass das CMSC-Verfahren ein effizientes und genaues Verfahren zur Lösung des hier gestellten Optimierungsproblems darstellt.

3.3 Ergebnisse und Folgerungen der Optimierung

Im Folgenden wird exemplarisch das Ergebnis einer durchgeführten Optimierung betrachtet. Das Ziel ist es, Erkenntnisse hinsichtlich der optimalen Unterstützung von Elektrofahrrädern zu

Tabelle 3: Variationsbereich der Parameter

Parameter	Normal	Erhöhung	Verringerung
P_{Fahrer} in W	100	+25 oder +50	-25 oder -50
m_{System} in kg	100	+30	-30
$c_w \cdot A$ in m^2	0,58	+0,07	-0,08
μ_r in 1	0,005	+0,0015	-0,0015




Bild 3: SoC-Trajektorien verschiedener Parameterkonfigurationen.

gewinnen. Dazu wird eine reale Strecke analysiert, die mit konstanter Fahrerleistung absolviert wird. Der Startwert SoC_0 und gewünschte Endwert SoC_f des SoCs sind vorgegeben. Die Ergebnisse der Optimierung sind in **Bild 2** dargestellt. Es handelt sich um eine Strecke mit ca. 8 km Länge. Neben der Geschwindigkeit sind der SoC, der Unterstützungsfaktor und die stückweise geglättete Steigung abgebildet.

Es ist zu sehen, dass die zur Verfügung stehende Energiemenge des Akkus vollständig ausgenutzt wird. Dies wurde bei der Problemformulierung der Optimierung so implementiert, ist jedoch hinsichtlich des Ziels der Minimierung der Fahrzeit zu erwarten. Eine schlechtere Energieausnutzung würde zu einer geringeren durchschnittlichen Geschwindigkeit und somit zu einer längeren Fahrzeit führen. Des Weiteren kann festgestellt werden, dass in Bereichen, in denen der Motor den Fahrer unterstützt ($x_{\text{assist}} > 0$), die Geschwindigkeit nahezu konstant ist. Diese optimale Unterstützungsgeschwindigkeit v_{opt} sollte somit bei der Fahrt mit dem Elektrofahrrad angestrebt werden. Das Verhalten ist auf den quadratischen Einfluss der Geschwindigkeit auf den Luftwiderstand zurückzuführen. Eine Erhöhung der Fahrgeschwindigkeit auf einen Wert oberhalb der optimalen Geschwindigkeit würde zu einer überproportionalen Zunahme des Energieverbrauchs führen. Diese könnte nur mit einer wesentlich stärkeren Reduzierung der Fahrgeschwindigkeit kompensiert werden, was hinsichtlich der Minimierung der Fahrzeit nicht optimal wäre. In Anbetracht dessen ist es optimal, bei einer geringeren verfügbaren Energiemenge die konstante optimale Geschwindigkeit zu verringern, anstatt den Energieverbrauch durch eine starke Reduzierung der Fahrgeschwindigkeit in einem kurzen Bereich zu senken. Aus der Forderung nach konstanter Geschwindigkeit ergibt sich eine Korrelation der Steigung und des Unterstützungsfaktors. Mit Zunahme der Steigung erhöht sich der Fahrwiderstand. Um die konstante Geschwindigkeit zu halten, muss die Antriebsleistung erhöht werden. Bei konstanter Fahrerleistung kann dies lediglich durch Erhöhung der Motorleistung bzw. des Unterstützungsfaktors erfolgen.

Im Weiteren wird der Einfluss variierender Modellparameter untersucht. Da im Betrieb des Elektrofahrrads nicht alle Parameter vorab bekannt sind oder diese sich während der Fahrt

ändern können, muss deren Auswirkung auf die optimale Fahrstrategie analysiert werden. Dazu werden die wesentlichen Parameter innerhalb eines realistischen Wertebereichs variiert, vgl. [19]. In **Tabelle 3** ist angegeben, um welchen Wert der jeweilige Parameter im Rahmen der Untersuchung erhöht bzw. reduziert wird.

Erzeugt ein abweichender Parameter eine Erhöhung des Fahrwiderstands bzw. verringert sich die Antriebsleistung, muss die Strecke mit einer geringeren optimalen Geschwindigkeit absolviert werden, um den geplanten Energieverbrauch einzuhalten. Bei umgekehrter Beeinflussung erhöht sich die optimale konstante Geschwindigkeit. So wird immer die zur Verfügung stehende Energie bestmöglich ausgenutzt. In **Bild 3** sind die SoC-Verläufe verschiedener Parameterkonfigurationen dargestellt. Auffällig ist hierbei, dass die jeweiligen optimalen Entladekurven nur geringe Unterschiede aufweisen. Das heißt, die SoC-Verläufe sind robust gegenüber Parameterschwankungen. Dies ist dadurch zu erklären, dass beispielsweise ein erhöhter Fahrwiderstand den Energieverbrauch bei gleicher Fahrgeschwindigkeit ebenfalls erhöhen würde. Da die zur Verfügung stehende Energie jedoch beschränkt ist, kann diese Geschwindigkeit nicht gefahren werden. Die optimale Geschwindigkeit muss reduziert werden, wodurch sich der Leistungsbedarf und der Energieverbrauch auch verringern. Das hat zur Folge, dass bei variierenden Parametern die optimalen SoC-Verläufe sich nur geringfügig unterscheiden. Jedoch weisen die optimalen Geschwindigkeiten eine große Varianz auf. Diese Erkenntnis ist hinsichtlich der optimalen Strategie auf dem Elektrofahrrad grundlegend. Somit kann trotz fehlendem Parameterwissen eine Entladekurve aufgestellt werden, die sich dem tatsächlichen optimalen SoC-Verlauf gut annähert.

4. Experimentelle Untersuchung der optimalen Unterstützungsstrategie

Nachdem die optimale Unterstützungssteuerung von Elektrofahrrädern unter idealen Bedingungen ermittelt wurde, werden Vergleiche zu herkömmlichen Fahrmodi aufgestellt. Dafür wird zuerst die optimale Lösung in einem physikalischen Modell in MATLAB/Simulink analysiert. Dieses Modell unterscheidet sich vom oben betrachteten DGL-Modell durch einen höheren

Detaillierungsgrad, realistischen Eingangssignalen sowie der Möglichkeit, Störungen aufzubringen. Danach erfolgt eine Betrachtung im realen Fahrversuch.

4.1 Untersuchung der optimalen Lösung im Modell

Durch Simulationen wird die vorab ermittelte optimale Unterstützungssteuerung analysiert und validiert. Hierbei wird die Zeitersparnis der optimierten Strategie im Vergleich zu einem herkömmlichen Fahrmodus bei gleichem Energieverbrauch betrachtet. In einer Simulation wird der Energieverbrauch im „Tour“-Modus ($x_{assist} = 120\%$) ermittelt. Dieser wird für die Berechnung der optimalen Lösung verwendet. Die so ermittelte Unterstützungsstrategie wird als Modelleingang für eine weitere Simulation eingesetzt. Exemplarisch werden drei Fahrten auf derselben Strecke mit unterschiedlicher Fahrerleistung betrachtet (siehe **Tabelle 4**).

Es ist zu sehen, dass unabhängig von der eingebrachten Leistung des Fahrers die optimierte Fahrstrategie eine kürzere Fahrzeit bei gleichem Energieverbrauch der Batterie ermöglicht. Somit kann gesagt werden, dass die mit dem CMSC-Verfahren ermittelte optimale Lösung eine bessere Fahrstrategie im Vergleich zum herkömmlichen Fahrmodus darstellt. Je nach Fahrerleistung beträgt das Einsparpotenzial über 10%. Der Vorteil nimmt mit zunehmender Fahrerleistung ab, da die optimale Geschwindigkeit v_{opt} immer weiter ansteigt. Dadurch nähern sich die optimale Strategie und der herkömmliche Fahrmodus einander an. Erreicht v_{opt} den gesetzlich maximal zulässigen Wert, kann sie nicht weiter ansteigen. In diesem Punkt entspricht die optimale Fahrstrategie der des herkömmlichen Fahrmodus. Aus diesem Grund ist das Potenzial bei niedriger Fahrerleistung größer, da die optimierte Fahrstrategie die Unterstützung des Elektrofahrrads stärker beeinflussen und die zur Verfügung stehende Energie zielgerichteter einsetzen kann.

Tabelle 4: Zeitersparnis durch optimale Unterstützungssteuerung

P_{Fahrer} in W	t in s (Tour)	t in s (optimal)	Einsparung in %
75	1427,8	1277,8	11,74
100	1231,2	1147,7	7,28
150	1061,0	1047,4	1,30

4.2 Untersuchung der optimalen Lösung im realen Fahrversuch

Neben der Simulation soll nun die optimale Lösung des CMSC-Verfahrens im Fahrversuch unter realen Bedingungen betrachtet werden. Hierzu wird eine Referenzfahrt mit einem herkömmlichen Unterstützungsmodus („Eco“-Modus, $x_{\text{assist}} = 50\%$) aufgezeichnet. Anhand der aufgezeichneten Daten wird die Optimierung durchgeführt. Die berechnete Strategie wird wegabhängig auf dem Elektrofahrrad hinterlegt und die Strecke damit nochmals gefahren. Dabei ist darauf zu achten, dass das Fahrverhalten möglichst identisch zu dem der Referenzfahrt gewählt wird. Da die Fahrt unter realen Bedingungen mit Unsicherheiten wie Wind und Verkehr stattfindet, ist eine komplette Übereinstimmung der beiden Fahrten nicht gewährleistet. Aus diesem Grund werden bei der Auswertung (siehe **Tabelle 5**) sowohl die eingebrachte Fahrerleistung (\bar{P}_{Fahrer}), der Energieverbrauch

($E_{\text{Verbrauch}}$) als auch die gefahrene Zeit (t) betrachtet.

Auch im realen Fahrversuch ist die optimierte Fahrstrategie vorteilhaft gegenüber dem herkömmlichen Unterstützungsmodus. Bei fast identischer durchschnittlicher Eingangsleistung wird die Strecke ca. 1 % schneller und mit 4 % geringerem Energieverbrauch absolviert. Bei gleichem Energieverbrauch wäre somit eine größere Zeitersparnis möglich gewesen. Die Vorteile der optimierten Steuerung werden auch bei Betrachtung der aufgezeichneten Messsignale ersichtlich (siehe **Bild 4**).

Der ähnliche Verlauf der Fahrerleistung belegt, dass das Fahrverhalten bei den beiden durchgeführten Testfahrten nahezu identisch ist. Bei der optimierten Fahrt ist ein konstanterer Geschwindigkeitsverlauf in den Bereichen mit Motorunterstützung ($x_{\text{assist}} > 0$) erkennbar. Dies ist auf den variablen und optimierten Verlauf des Unterstützungsfaktors zurückzuführen. Dadurch gibt die Batterie die Leistung an die Fahrsituation angepasst ab. Dies führt ebenfalls zu einem variableren Energieverbrauch der Batterie. Im Gegensatz dazu, weist der herkömmliche Fahrmodus mit konstanter Unterstützung eine konstantere Leistungseinbringung und somit auch einen konstanteren Energieverbrauch auf. Dadurch kann beispielsweise an Anstiegen nur eine geringe Geschwindigkeit erzielt werden, wohingegen in der Ebene mit einer höheren Geschwindigkeit gefahren wird. Wie eingangs analysiert, ist eine konstante Fahrgeschwindigkeit aus energetischer Sicht vorteilhaft. Dies wird von der optimierten Fahrstrategie angestrebt. Dadurch stellt diese eine Verbesserung des Fahrverhaltens dar. Die zur Verfügung stehende Energie wird zielgerichteter eingesetzt als bei den herkömmlichen Fahrmodi, was zu einer gleichmäßigeren Fahrgeschwindigkeit und somit auch zu einem gleichmäßigeren Fahrgefühl führt.

Tabelle 5: Ergebnisse der Referenz- und optimierten Fahrt (Fahrversuch)

	Referenz	Optimiert	Vorteil
\bar{P}_{Fahrer} in W	100	101	—
$E_{\text{Verbrauch}}$ in Wh	31,04	29,83	-3,90 %
t in s	1501	1489	-0,80 %

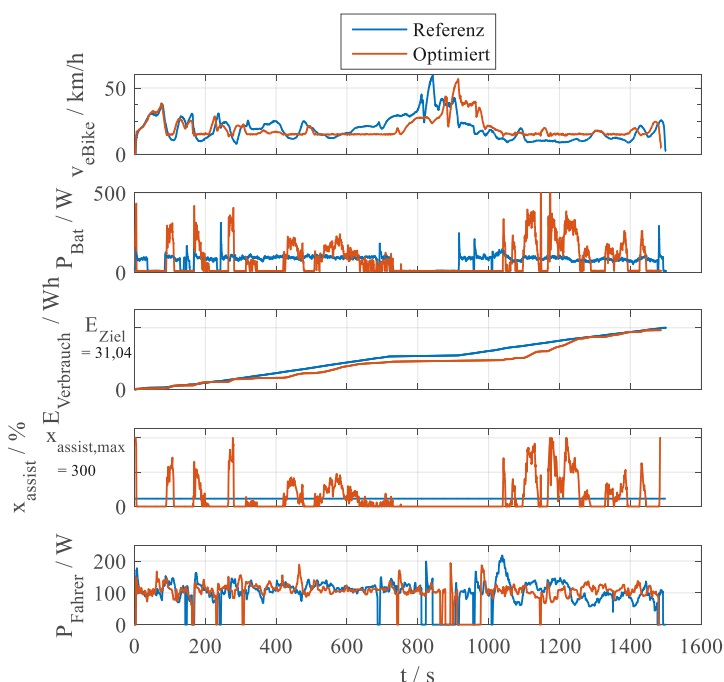


Bild 4: Optimale Lösung im Fahrversuch.

5. Diskussion der Ergebnisse

Wie bei den Untersuchungen im Modell und Fahrversuch ersichtlich wurde, kann durch den optimierten Fahrmodus dieselbe Strecke bei gleichem Energieverbrauch in kürzerer Zeit absolviert werden. Dies ermöglicht dem Fahrer bei beschränkter Akkukapazität die bestmögliche Ausnutzung der zur Verfügung stehenden

AUTOREN VITA



Tobias Lipowsky, M.Sc.

2009–2013 Maschinenbaustudium (Abschluss: Bachelor of Science), Universität Stuttgart

2013–2015 Studium im Bereich Maschinenbau/Produktentwicklung und Konstruktionstechnik (Abschluss: Master of Science), Universität Stuttgart

Seit 2015 Vorausbauentwicklung, Bosch eBike Systems

Kontakt

Robert Bosch GmbH
Robert-Bosch-Platz 1
70839 Gerlingen-Schillerhöhe
E-Mail: Tobias.Lipowsky@de.bosch.com



Dr.-Ing. Evgeny Lazutkin

2006–2010 Studium der Metrologie und Messtechnik (Abschluss: Bachelor of Science), Nationalen Forschungsuniversität „Moscow Power Engineering Institute“

2010–2012 Studium im Fachbereich „Electrical Power and Control Engineering“ (Abschluss: Master of Science mit Auszeichnung „Best Student Award“), TU Ilmenau

2012–2018 Wissenschaftlicher Mitarbeiter an der Fakultät für Informatik und Automatisierung, FG Simulation und optimale Prozesse, TU Ilmenau

2013–2018 Promotionsstudium mit dem Thema „Efficient solution approach to nonlinear optimal control problems and application to autonomous driving“, TU Ilmenau

Seit 2018 Postdoc an der Fakultät für Informatik und Automatisierung, FG Prozessoptimierung, TU Ilmenau

Kontakt

Fachgebiet Prozessoptimierung
Institut für Automatisierungs- und Systemtechnik
Technische Universität Ilmenau
Helmholtzplatz 5
98693 Ilmenau
E-Mail: Evgeny.Lazutkin@tu-ilmenau.de



Dr. Jürgen Stegmaier

2002–2007 Maschinenbaustudium (Abschluss: Diplom), TU München

2011 Promotion im Bereich Waste-Heat-Recovery, TU Kaiserslautern

Seit 2010 Systementwicklung, Bosch eBike Systems

Kontakt: E-Mail: Juergen.Stegmaier2@de.bosch.com



Jan Schnee, M.Sc.

2012–2016 Studium der Medizintechnik (Abschluss: Bachelor of Science), Hochschule Furtwangen, Campus Tuttlingen

2016–2017 Studium der Mechatronik (Abschluss: Master of Science), Hochschule Reutlingen

Seit 2017 Vorausbauentwicklung, Inertialsensorik basierte Funktionen, Bosch eBike Systems

Kontakt: E-Mail: Jan.Schnee@de.bosch.com



Prof. Dr.-Ing. habil. Pu Li

1978–1982 Studium der Automatisierungstechnik, Shenyang Institute of Chemical Technology, China

1982–1986 Wissenschaftlicher Mitarbeiter, Fushun Petroleum Institute, China

1986–1989 Master of Engineering, Zhejiang University, China

1989–1994 Wissenschaftlicher Mitarbeiter, Fushun Petroleum Institute, China

1998 Promotion zum Dr.-Ing., TU Berlin

1999–2005 Oberingenieur und Habilitation zum Thema Prozessoptimierung, TU Berlin

Seit 2005 Universitätsprofessor und Leiter des Fachgebiets Prozessoptimierung am Institut für Automatisierungs- und Systemtechnik, TU Ilmenau

Kontakt: E-Mail: Pu.Li@tu-ilmenau.de

Energie bei gleichzeitig optimaler Fahrzeit. Das Einsparpotenzial, im Vergleich zu einem herkömmlichen Fahrmodus, lag in einem Bereich von 1–12 %. Dieser große Bereich zeigt auf, dass eine pauschale Aussage schwierig ist, da viele

Faktoren dieses Potenzial beeinflussen. Neben der Strecke haben das Fahrverhalten, die Umweltbedingungen und Fahrradparameter einen Einfluss. Dies entspricht der Aussage der Arbeit von Sciarretta und Guzzella zur Regelung von

Tabelle 6: Potenzialabschätzung der optimierten Unterstützung

Parameter	Veränderung	Einfluss
E_{Bat}	Abnahme	Potenzial steigt
$\varnothing V_{\text{eBike}}$	Abnahme	Potenzial steigt
$\varnothing P_{\text{Fahrer}}$	Abnahme	Potenzial steigt
$F_{\text{Wid.}}$	Abnahme	Potenzial sinkt

Hybridfahrzeugen in [30], in der eine starke Abhängigkeit des Potenzials vom Fahrzyklus und Fahrzeug erkannt wurde. Allerdings kann als Trend festgestellt werden (siehe **Tabelle 6**), dass je größer die Einflussmöglichkeiten der optimierten Fahrstrategie sind, das heißt, je stärker diese sich von den herkömmlichen Fahrmodi unterscheiden kann, desto größer ist auch das erzielbare Einsparpotenzial.

Umsetzbarkeit auf dem Elektrofahrrad

Bei Betrachtung der erzielten Ergebnisse der optimierten Fahrstrategie kann diese bei entsprechender Umsetzung auf dem Elektrofahrrad zur Bekämpfung der Reichweitenangst des Fahrers des Elektrofahrrads beitragen. Hinsichtlich der Reichweitenangst stehen für den Nutzer das Einhalten der zur Verfügung stehenden Energie und damit das sichere Ankommen am gewünschten Ziel im Fokus, die Zeitoptimalität ist zweitrangig. Hierbei ist die gewonnene Erkenntnis hinsichtlich der robusten SoC-Trajektorie von entscheidender Bedeutung. Basierend auf der SoC-Trajektorie kann ein Regler entworfen werden, der die Unterstützung des Elektrofahrrads entsprechend dem tatsächlichen Energieverbrauch, selbst bei unbekanntenen Parametern, einstellt. Allerdings stellt die Berechnung der SoC-Trajektorie für den Einsatz auf dem Elektrofahrrad ein Problem dar. Selbst der effiziente CMSC-Ansatz benötigt bereits bei kurzen Strecken auf einem leistungsstarken Computer mehrere Minuten. Dies ist ein Ausschlusskriterium für den Einsatz auf dem Elektrofahrrad. Abhilfe könnte eine vereinfachte Berechnung schaffen, die unter Annahmen die optimale Lösung annähert und eine schnellere Berechnung ermöglicht. Alternativ kann die Planung nur für kurze Strecken implementiert werden, um am Ende der Strecke die Optimalität sowie die Einhaltung des Energieverbrauchs sicherzustellen. Eine serverbasierte Berechnung der optimalen Strategie in leistungsstarken Rechenzentren und anschließende drahtlose Übertragung auf das Elektro-

fahrrad könnten ebenfalls eine mögliche Lösung für das Problem darstellen. Jedoch müssten dafür die Elektrofahrräder mit entsprechenden Empfangsmodulen ausgestattet werden. Dieses Problem muss zukünftig angegangen werden, um eine automatisierte und optimierte Unterstützungssteuerung zu ermöglichen und dadurch eine Minderung der Reichweitenangst des Nutzers sowie eine größere Verbreitung von Elektrofahrrädern zu erreichen.

6. Zusammenfassung und Ausblick

Mit dieser Arbeit wurde ein Beitrag zur Bekämpfung der Reichweitenangst bei Elektrofahrrädern, einem der Hauptprobleme der Elektromobilität, geleistet. Die optimale Unterstützungsstrategie wurde bei bekannter Strecke und vorgegebener Akkukapazität mithilfe des CMSC-Verfahrens ermittelt. Dabei hat sich eine konstante Geschwindigkeit als optimal herausgestellt. Zusätzlich konnte festgestellt werden, dass die SoC-Trajektorie robust gegenüber Parameterunsicherheiten ist und selbst bei größeren Einflüssen nur minimal vom ursprünglichen Verlauf abweicht. In Simulationen und im Fahrversuch konnte gezeigt werden, dass die optimierte Fahrstrategie Vorteile gegenüber den herkömmlichen Fahrmodi aufweist. Hierbei konnte dieselbe Strecke bei gleichem Energieverbrauch über 10 % schneller absolviert werden. Aufgrund der vielen Einflussfaktoren ist eine pauschale Aussage hinsichtlich des Vorteils jedoch nicht möglich. Für den Nutzer des Elektrofahrrads ist dieses Ersparnis, im Vergleich zum sicheren Ankommen mit der zur Verfügung stehenden Akkukapazität, jedoch zweitrangig. Wie in der Diskussion angesprochen, sollten sich zukünftige Arbeiten mit der Umsetzung der hier durchgeführten Forschung auf dem Elektrofahrrad beschäftigen. Das Ziel sollte dabei ein neuartiger, optimierter Fahrmodus sein, der die Unterstützung in Abhängigkeit der geplanten Strecke und der verbleibenden Akkukapazität automatisch anpasst. Dadurch kann der Reichweitenangst entgegen gewirkt werden. Dies sollte mit Nutzerstudien über einen längeren Zeitraum überprüft werden. Des Weiteren sollte untersucht werden, inwieweit die hier gewonnenen Erkenntnisse auf Elektrofahrzeuge anderer Bereiche übertragen werden können.

Literatur

- [1] G. Alli, S. Formentin und S. M. Savaresi: On the suitability of EPACs in urban use. *IFAC Proceedings Volumes*, Bd. 43, S. 277–284, 2010.
- [2] C. C. Hua, S. J. Kao und Y. H. Fang: Design and implementation of a regenerative braking system for electric bicycles with a DSP controller. In *2013 1st International Future Energy Electronics Conference (IFEEEC)*, 2013.
- [3] A. Muetze und Y. C. Tan: Electric bicycles – A performance evaluation. *IEEE Industry Applications Magazine*, Bd. 13, S. 12–21, 7 2007.
- [4] A. Muetze und Y. C. Tan: Performance evaluation of electric bicycles. In *Fortieth IAS Annual Meeting. Conference Record of the 2005 Industry Applications Conference*, 2005.
- [5] P. Spagnol, G. Alli, C. Spelta, P. Lisanti, F. Todeschini, S. M. Savaresi und A. Morelli: A full hybrid electric bike: How to increase human efficiency. In *2012 American Control Conference (ACC)*, 2012.
- [6] S. Vogt und J. Orth: Zukünftige Entwicklungen in der Mobilität: Betriebswirtschaftliche und technische Aspekte. Wiesbaden, Gabler Verlag, 2012, S. 105–119.
- [7] ZIV – Zweirad Industrie-Verband: E-Bike-Markt wächst weiter – Absatz von Fahrrädern rückläufig Stimmungsbarometer für das 1. Halbjahr 2017. www.ziv-zweirad.de/fileadmin/redakteure/Downloads/Marktdaten/PM_2017_29.08._Fahrradmarkt_1._HJ_2017.pdf (abgerufen am 07.02.2018).
- [8] U. Eberle und R. von Helmolt: Sustainable transportation based on electric vehicle concepts: a brief overview. *Energy Environ. Sci.*, Bd. 3, S. 689–699, 2010.
- [9] T. Lipowsky, J. Stegmaier, M. Lang und P. Li: Simulative potential assessment of regenerative braking with electric bicycles under consideration of realistic boundary conditions. In *2017 International Conference on Research and Education in Mechatronics (REM)*, 2017.
- [10] O. Maier, M. Krause, S. Krauth, N. Langer, P. Pascher und J. Wrede: Potential benefit of regenerative braking on electric bicycles. In *2016 IEEE International Conference on Advanced Intelligent Mechatronics (AIM)*, 2016.
- [11] D. Schneider: Easy rider. *IEEE Spectrum*, Bd. 46, S. 26–27, 9/2009.
- [12] A. Fuchs: Principles of Human-Electric Hybrid Drives for Human Powered Vehicles. In *Paper for the 6th European Seminar on Velomobile Design Copenhagen*, 2009.
- [13] BMVI – Bundesministerium Verkehr und digitale Infrastruktur: Elektrofahrräder – Einstufung von Elektrofahrrädern (Pedelecs). www.bmvi.de/SharedDocs/DE/Artikel/LA/elektrofahrraeder.html (abgerufen am 13.10.2017)
- [14] B. Heißing, M. Ersoy und S. Gies: *Fahrdynamik*. Wiesbaden, Springer Fachmedien Wiesbaden, 2013, S. 38–155.
- [15] D. Naunin: *Hybrid-, Batterie- und Brennstoffzellen-Elektrofahrzeuge: Technik, Strukturen und Entwicklungen*. Expert-Verlag, 2007.
- [16] W.-Y. Chang: *The State of Charge Estimating Methods for Battery: A Review*. ISRN Applied Mathematics, 2013.
- [17] J. Dambrowski: Review on Methods of State-of-Charge Estimation with Viewpoint to the Modern LiFePO₄/Li₄Ti₅O₁₂ Lithium-Ion Systems. In *INTELEC 2013 – The 35th International Telecommunication Energy Conference*, Hamburg, 2013.
- [18] S. Piller, M. Perrin und A. Jossen: Methods for state-of-charge determination and their applications. *Journal of Power Sources*, Bd. 96, S. 113–120, 2001.
- [19] T. Lipowsky, J. Stegmaier und P. Li: Comprehensive measurement approach for determining parameters of a motor-assisted single-track vehicle. In *Bicycle and Motorcycle Dynamics 2016*, 2016.
- [20] J. Tamimi und P. Li: Nonlinear model predictive control using multiple shooting combined with collocation on finite elements. In *7th IFAC Int. Symp. on Advanced Control of Chemical Processes*, 2009.
- [21] J. Tamimi und P. Li: A combined approach to nonlinear model predictive control of fast systems. *Journal of Process Control*, Bd. 20, S. 1092–1102, 2010.
- [22] E. Lazutkin, A. Geletu, S. Hopfgarten und P. Li: Modified Multiple Shooting Combined with Collocation Method in JModelica.org with Symbolic Calculations. In *10th International Modelica Conference*, 2014.
- [23] E. Lazutkin, A. Geletu, S. Hopfgarten und P. Li: An Analytical Hessian and Parallel-Computing Approach for Efficient Dynamic Optimization Based on Control-Variable Correlation Analysis. *Industrial & Engineering Chemistry Research*, Bd. 54, S. 12086–12095, 2015.
- [24] A. Wächter und L. T. Biegler: On the implementation of an interior-point filter line-search algorithm for large-scale nonlinear programming. *Mathematical Programming*, Bd. 106, S. 25–57, 2006.
- [25] D. Ambühl: *Energy management strategies for hybrid electric vehicles*. 2009.
- [26] S. A. Fayazi, N. Wan, S. Lucich, A. Vahidi und G. Mocko: Optimal pacing in a cycling time-trial considering cyclist's fatigue dynamics. In *2013 American Control Conference*, 2013.
- [27] T. Radke: *Energieoptimale Längsführung von Kraftfahrzeugen durch Einsatz vorausschauender Fahrstrategien*. 2013.
- [28] N. Wan, S. A. Fayazi, H. Saeidi und A. Vahidi: Optimal power management of an electric bicycle based on terrain preview and considering human fatigue dynamics. In *American Control Conference (ACC)*, 2014.
- [29] O. Sundstrom und L. Guzzella: A generic dynamic programming Matlab function. In *2009 IEEE Control Applications, (CCA) Intelligent Control, (ISIC)*, 2009.
- [30] A. Sciarretta und L. Guzzella: Control of hybrid electric vehicles. *IEEE Control Systems Magazine*, Bd. 27, S. 60–70, 4 2007.