Hochschule München University of Applied Sciences

Bachelorarbeit

Bachelor's Thesis

Marktstudie und Analyse moderner Inverter-Software: Aktuelle Methoden der Parametererfassung und zukünftige Entwicklungen

Market Study and Analysis of Modern Inverter Software: Current Parameter Acquisition Methods and Future Developments

Hochschule für angewandte Wissenschaften München
Fakultät für Maschinenbau, Fahrzeugtechnik und Flugzeugtechnik

Angefertigt von: **Berkant Kadir Ayaz**
Studiengang: **MBB**
Matrikelnummer:
Betreuer: **Prof. Dr.-Ing. Michael Hofmann**

Sommersemester 2025
Eingereicht am: 24.09.2025

Eigenständigkeitserklärung

Hiermit erkläre ich, dass ich die Bachelorarbeit selbstständig verfasst, noch nicht anderweitig für Prüfungszwecke vorgelegt, keine anderen als die angegebenen Quellen oder Hilfsmittel benutzt, sowie wörtliche und sinngemäße Zitate als solche gekennzeichnet habe.

Ort, Datum: München, 24.09.2025 Unterschrift:

Kurzfassung/Abstract

Diese Arbeit führt eine Marktstudie durch, um bestehende Methoden und Lösungen zur Erfassung der Parameter einer elektrischen Maschine durch Inverter-Software zu analysieren. Die Verfahren zur Parametererfassung einer elektrischen Maschine durch Inverter-Software werden behandelt, verglichen und mit den aktuellen Inverter-Softwarelösungen, die auf dem Markt sind, zusammengeführt. Zudem werden zukünftige potenzielle Methoden und Trends zur Parametererfassung einer elektrischen Maschine durch Inverter-Software analysiert sowie zukünftige Inverter-Software betrachtet. Die potenziellen Methoden und Trends werden mit den bereits bestehenden Methoden verglichen. Die Ergebnisse dieser Arbeit sollen einen Überblick über die aktuellen Methoden der Parametererfassung elektrischer Maschinen durch Inverter, die Funktion bestehender Softwarelösungen zur Parametererfassung sowie Entwicklungsperspektiven bezüglich der Methoden und Inverter-Software zur Parametererfassung für die kommenden Jahre aufzeigen.

Verwendete Formelzeichen

Formelzeichen	Einheit	Bezeichnung
A	[–]	Systemmatrix der Zustandsraummodellierung
b	[–]	Eingangsspaltenvektor (SISO-Variante der Eingangsmatrix B)
b_0	[–]	Nenndurchgriffsfaktor / Systemverstärkung in ADRC
B	[–]	Eingangsmatrix der Zustandsraummodellierung
c^T	[–]	Transponierter Ausgangsvektor (SISO-Variante von C)
C	[–]	Ausgangsmatrix der Zustandsraummodellierung
c_T	[Nm/A]	Momentenbezugskonstante
$\Delta e(k)$	[–]	Änderung der Fehlergröße zwischen zwei Zeitschritten
Δy	[–]	Innovationssignal (Differenz zwischen y und $\hat{y}$)
$\Delta u_{s,hf}$	[V]	Hochfrequente eingespeiste Wechselspannung (HF-Injektion)
$\Delta i_{s,hf}$	[A]	Hochfrequenter Strom infolge der HF-Injektion
e	[–]	Fehlergröße (Differenz zwischen Ist- und Sollwert oder Ausgangsfehler)
$e(k)$	[–]	Fehlergröße zum Zeitpunkt k
f	[Hz]	Frequenz am Motorausgang
f_N	[Hz]	Nennfrequenz (z. B. 50 Hz)
f_S	[Hz]	Netzfrequenz
$f(\Delta\theta)$	[–]	Demodulationsfunktion des Lagewinkelfehlers
F	[Nms]	Reibungs- bzw. Dämpfungskoeffizient
G	[–]	Verstärkungsmatrix/-vektor für Sliding-Mode-Anteil des Beobachters
i_a, i_b, i_c	[A]	Statorströme der drei Phasen (abc-System)
i_α, i_β	[A]	Stromkomponenten im $\alpha\beta$-System

$i_{\alpha h}, i_{\beta h}$	[A]	Hochfrequenzanteile der Ströme nach BPF
i_d, i_q	[A]	Stromkomponenten im dq-System
i_D, i_Q	[A]	Ströme in D- und Q-Achse
i_{sd}, i_{sq}	[A]	Statorstrom-Komponenten im dq-System
i_{sd}^*, i_{sq}^*	[A]	Sollwerte der Statorstrom-Komponenten
i_k	[A]	Strom der Dämpferwicklung (erweitertes Maschinenmodell)
i_p	[A]	gemessene Stromkomponente (z. B. in $\alpha\beta$)
I_{DC}	[A]	Zwischenkreisstrom
$I_I(j\omega)$	[A]	Komplexer Strom der Eingangsphase
I_N	[A]	Nennstrom
J	[kg·m^2]	Trägheitsmoment
$K(N)$	[–]	Gewinnvektor der RLS-Iteration
K_p, K_i	[–]	PI-Reglerparameter
K_t	[Nm/A]	Drehmomentkonstante
k	[–]	Beobachterverstärkung (SISO-System), entspricht L
L	[–]	Beobachterverstärkung (Luenberger-Gain)
L_d	[H]	d-Achsen-Induktivität
L_q	[H]	q-Achsen-Induktivität
L_m	[H]	Magnetisierungsinduktivität
L_r	[H]	Rotorinduktivität
L_s	[H]	Statorinduktivität
L_σ	[H]	Leckinduktivität (Gesamt)
$L_{\sigma 1}$	[H]	Stator-Leckinduktivität
$L_{\sigma 2}$	[H]	Rotor-Leckinduktivität
λ	[–]	Vergessensfaktor der RLS ($0 < \lambda \leq 1$)
M	[Nm]	Drehmoment
$M_{t(max)}$	[Nm]	Maximales Drehmoment
n_N	[1/min]	Nenndrehzahl
n_s	[1/min]	Synchrondrehzahl
p	[–]	Polpaarzahl
$P(N)$	[–]	Kovarianzmatrix der Parameterschätzung (RLS)
P_{cu}	[W]	Kupferverluste
P_{fe}	[W]	Eisenverluste

P_N	[W]	Nennleistung
$r[k]$	[–]	Normalisierungsfaktor der RPEM-Iteration
R_1	[Ω]	Statorwiderstand im Ersatzschaltbild
R_{Fe}	[Ω]	Eisenverlustwiderstand
R_I	[Ω]	Widerstand der Phase I
R_m	[Ω]	Identifizierter Statorwiderstand
R_r	[Ω]	Rotorwiderstand
R_s	[Ω]	Statorwiderstand
$\hat{R}_s$	[Ω]	Geschätzter Statorwiderstand
$\hat{R}_{s,0}$	[Ω]	Initialer Schätzwert des Statorwiderstands
s	[–]	Schlupf der Asynchronmaschine
T_e	[Nm]	Elektromagnetisches Drehmoment
T_e^*	[Nm]	Sollwert des elektromagnetischen Drehmoments
$T(k)$	[Nm]	Drehmoment zum Zeitpunkt k (diskret)
T_m	[Nm]	Mechanisches Lastmoment
T_r	[s]	Rotorzeitkonstante
τ_{th}	[s]	Thermische Zeitkonstante
u	[V]	Eingangssignal (z. B. Statorspannung)
u_a	[V]	Eingangsspannung für Rm-Identifikation
u_s	[V]	Ständerspannung
u_{sd}, u_{sq}	[V]	dq-Spannungen
u_{sd}^*, u_{sq}^*	[V]	Sollspannungen dq-System
u_{sd}^{DC}, u_{sq}^{DC}	[V]	DC-Offset-Spannungen
u_{dr}, u_{qr}	[V]	Referenzspannungen dq-System
$u_{\alpha r}, u_{\beta r}$	[V]	Referenzspannungen $\alpha\beta$-System
U	[V]	Motorspannung am Wechselrichterausgang
$\hat{U}$	[V]	Amplitude der eingespeisten Spannung
U_{DC}	[V]	Zwischenkreisspannung
U_h	[V]	Spannung über der Magnetisierungsinduktivität
$U_I(j\omega)$	[V]	Komplexe Spannung der Eingangsphase
U_N	[V]	Nennspannung
U_S	[V]	Netzspannung
$X_{\sigma 1}, X_{\sigma 2}$	[Ω]	Leckreaktanzen
X_h	[Ω]	Hauptreaktanz
X_k	[Ω]	Reaktanz der Dämpferwicklung

Z_K	[Ω]	Impedanz der Maschine im Kurzschlussversuch
$Z_L(j\omega)$	[Ω]	Komplexe Impedanz der Maschine
z_1, z_2	[–]	Zustandsvariablen des ESO in ADRC
$\gamma[k]$	[–]	Schrittweite (Lernrate) der RPEM-Iteration
$\hat{x}(t)$	[–]	Geschätzter Zustandsvektor
$\dot{\hat{x}}$	[–]	Zeitableitung des geschätzten Zustandsvektors
$\hat{y}$	[–]	Geschätzter Ausgang des Systems
x	[–]	Zustandsvektor
$\dot{x}(t)$	[–]	Zeitableitung des Zustandsvektors
$\bar{\psi}_s$	[Vs]	Integrierter Ständerfluss
Ψ_r (auch ψ_r)	[Vs]	Rotorfluss
Ψ_s	[Vs]	Statorfluss
Ψ_{PM}	[Vs]	Permanentmagnetfluss
Φ_{res}	[Vs]	Restmagnetisierung
$\varphi(N)$	[–]	Regressorvektor der RLS
φ_D, φ_Q	[rad]	Winkelpositionen der D- und Q-Achse
φ_{M0}	[rad]	Mechanische Rotorposition
y	[–]	Ausgangsgröße / Messgröße
θ	[–]	Parametersatz / Schätzvektor
Θ_r	[rad]	Rotorlage (elektrischer Winkel)
$\hat{\theta}_r$	[rad]	Geschätzte Rotorlage
$\hat{\theta}(N)$	[–]	Parameterschätzer zum Zeitpunkt N
ω_e	[rad/s]	Elektrische Winkelgeschwindigkeit
ω_r	[rad/s]	Mechanische Drehzahl / Rotordrehzahl
$\hat{\omega}_r$	[rad/s]	Geschätzte Rotordrehzahl
$\mathrm{sgn}(\cdot)$	[–]	Signum-Funktion (+1 / –1)
$\Re\{\cdot\}$	[–]	Realteil einer komplexen Zahl
$\Im\{\cdot\}$	[–]	Imaginärteil einer komplexen Zahl

Abkürzungsverzeichnis

Abkürzung	Bedeutung
ADRC	Active Disturbance Rejection Control
ANN	Artificial Neural Network
aufw.	Aufwand (Implementierungs- oder Rechenaufwand)
DC	Direct Current (Gleichstrom)
DFTE	Direct Flux and Torque Estimation
DTC	Direct Torque Control
EKF	Extended Kalman Filter
EMV	Elektromagnetische Verträglichkeit
ESO	Extended State Observer
FOC	Field Oriented Control
GPSO	Guaranteed Particle Swarm Optimization
HF	Hochfrequenz (High Frequency)
hochdyn.	Hochdynamisch (geeignet für Systeme mit schnellen Zustandsänderungen)
ID	Identification (ID-Run)
IGBT	Insulated Gate Bipolar Transistor
IM	Induktionsmaschine
KI	Künstliche Intelligenz
linear.	Linearität (Eignung der Methode für lineare Systeme)
MOSFET	Metal-Oxide-Semiconductor Field-Effect Transistor
MRAS	Model Reference Adaptive System
PI	Proportional-Integral-Regler
PINN	Physics-Informed Neural Network
PSO	Particle Swarm Optimization
PWM	Pulsweitenmodulation
rob.	Robustheit gegenüber Störungen
RPEM	Recursive Prediction Error Method
SVM	Support Vector Machine

Inhaltsverzeichnis

Verwendete Formelzeichen iii
Abkürzungsverzeichnis vii

1 Einleitung: Relevanz und Zielsetzung moderner Inverter-Technologien 1
1.1 Problemstellung 2
1.2 Zielsetzung der Arbeit 2
1.3 Aufbau der Arbeit 3

2 Die Funktion und Bedeutung moderner Inverter 4
2.1 Grundlagen moderner Inverter 5
2.2 Rolle der Software bei Invertern in Bezug auf die Parametererfassung 6

3 Parametererfassung: Wichtige Maschinenparameter und Methoden 8
3.1 Zielsetzung und Rolle der Parametererfassung 8
3.2 Zentrale Maschinenparameter und deren Einflussgrößen 8
3.3 Aktuelle Methoden der Parametererfassung 12
3.4 Offline-Parametererfassung 14
3.4.1 Typenschildbasierte Abschätzung 14
3.4.2 Gleichstromversuch 16
3.4.3 Leerlaufversuch 17
3.4.4 Kurzschlussversuch 18
3.4.5 Rampentest/Low-Speed Test 19
3.4.6 Standstill Identification 20
3.4.7 Least Squares (als Auswertemethode) 22
3.4.8 Self-Commissioning 23
3.4.9 Zusammenfassung der Offline-Methoden 25
3.5 Online-Parametererfassung 26
3.5.1 Injektionsbasierte Verfahren 27
3.5.1.1 DC Signal Injection 29
3.5.1.2 HF Signal Injection 31
3.5.1.3 Rotating Voltage Injection 32
3.5.1.4 Pulsinjektion 32
3.5.2 Observer-gestützte Methoden 33
3.5.2.1 Luenberger Observer 35
3.5.2.2 Sliding Mode Observer 37
3.5.2.3 Model Reference Adaptive System (MRAS) 38

3.5.2.4 Extended Kalman Filter . . . 39
3.5.2.5 Direct Flux and Torque Estimation . . . 40
3.5.2.6 Recursive Least Squares . . . 41
3.5.3 Zusammenfassung der Online-Methoden . . . 42
3.6 Adaptive/Intelligente Methoden . . . 43
3.6.1 Fuzzy-Logic-Controller . . . 44
3.6.2 Support Vector Machines . . . 45
3.6.3 Genetic Algorithms . . . 46
3.6.4 GPSO/PSO . . . 48
3.6.5 Differential Evolution . . . 49
3.6.6 Neuronale Netze . . . 51
3.6.7 Zusammenfassung der adaptiv/intelligenten Methoden . . . 52
3.7 Vergleich der Methoden zur Parametererfassung elektrischer Maschinen und Auswahlkriterien . . . 53
3.7.1 Entscheidungskriterien für die Auswahl geeigneter Verfahren . . . 55

4 Marktanalyse aktueller Inverter-Software 58
4.1 Marktanalysemethode . . . 58
4.2 Siemens SINAMICS . . . 58
4.3 ABB ACS880 . . . 60
4.4 Danfoss EC-C1200 . . . 61
4.5 Weitere Softwarelösungen . . . 63
4.6 Vergleich der Softwarelösungen und Fazit . . . 63

5 Zukunftsperspektiven zur Inverter-Software und Parametererfassung 66
5.1 Potenzielle Methoden zur Parametererfassung . . . 66
5.1.1 Recursive Prediction Error Method (RPEM) . . . 66
5.1.2 MRAS mit Active Disturbance Rejection Control) . . . 67
5.1.3 Physics-Informed Neural Networks . . . 68
5.1.4 Chirp-Signal-Identification . . . 70
5.1.5 Vergleich der potenziellen Methoden und Fazit . . . 70
5.2 Potenzielle Softwarelösungen . . . 72
5.2.1 Cloud-Lösungen . . . 73
5.2.2 Edge-Lösungen . . . 74

6 Schluss: Erkenntnisse und Ausblick 75
6.1 Zusammenfassung der Ergebnisse . . . 75
6.2 Ausblick und Handlungsempfehlungen . . . 76

Abbildungsverzeichnis 78

Tabellenverzeichnis **80**

Literaturverzeichnis **81**

1 Einleitung: Relevanz und Zielsetzung moderner Inverter-Technologien

Die Bedeutung elektrischer Maschinen in der Industrie nimmt seit Jahren zu. Elektrische Maschinen spielen eine zentrale Rolle in der Industrie sowie im Alltag. Die Steuerung elektrischer Maschinen und die Stromumwandlung für den Betrieb dieser Maschinen erfolgen durch moderne Inverter-Technologien, die den Strom zwischen der elektrischen Maschine und der Energiequelle regeln (Hagl 2024, S. 194).

Die zentrale Rolle der elektrischen Maschinen in der Industrie hat die Anforderungen an diese Maschinen ebenfalls verändert und weiterentwickelt (Fischer und Nolle 2022, S. 11). Neben den Hauptmerkmalen wie Leistung und Qualität spielen nun auch die Regelung, Überwachung und insbesondere die automatisierte Parametrierung einer elektrischen Maschine eine große Rolle (Schröder und Böcker 2021, S. 498).

Die Motorenparameter sind entscheidend für eine problemlose Regelung, Effizienz und Langlebigkeit der elektrischen Maschine. Eine fehlerhafte oder ungenaue Parametrierung kann zu Instabilitäten und Effizienzverlusten führen (Tang u. a. 2018, S. 1).

Ein wichtiges Ziel moderner Inverter besteht darin, nicht nur die klassischen Funktionen wie die Bereitstellung von Spannung und Frequenz zu übernehmen, sondern den Motorbetrieb durch präzise Kenntnis seiner physikalischen Parameter zu optimieren. Hierfür ist eine Parametererfassung der elektrischen Maschine nötig (Odhano 2014, S. 1).

Die Parameter, die erfasst werden müssen, variieren je nach deren Anwendungszweck, und die häufigsten sind z. B. Widerstand, Induktivität und Trägheitsmoment (Odhano u. a. 2019, S. 3604).

In der Industrie werden verschiedene Inverter eingesetzt für die Parametererfassung elektrischer Maschinen. Diese führen automatisierte Prozesse durch, wie z. B. das Self-Commissioning-Verfahren, indem sie klassische Parametererfassungsverfahren nacheinander durchführen (Kania u. a. 2011, S. 1-2; Odhano u. a. 2019, S. 3606).

Die Relevanz solcher Verfahren zur Parametererfassung nimmt mit der steigenden Komplexität und den Anforderungen der Systeme zu. Die bestehenden Praxislösungen werden weiterentwickelt, optimiert und verbessert, während in der Forschung neue und intelligente Methoden zur Parametererfassung entwickelt werden.

1.1 Problemstellung

Moderne Inverter können heutzutage viele Maschinenparameter erfassen (Odhano 2014, S. 5). Dabei entstehen Rohdaten, die ausgewertet werden müssen, und daraus werden die endgültigen Maschinenparameter abgeleitet. Die Rohdaten können auf verschiedenste Weise erfasst, ausgewertet und in präzise Maschinenparameter umgewandelt werden, welche dann auch für die Regelung und Effizienz der Maschine eine große Rolle spielen.

Je nach Anwendung der Maschine, dem Bedarf an Parametern und der Verfügbarkeit von Infrastruktur kann die Parametererfassung auf unterschiedliche Weise erfolgen: mit oder ohne Sensorik, mit oder ohne Messtechnik, automatisiert oder manuell, durch Inverter oder durch separate Aufbauten (Schröder und Böcker 2021, S. 499, 501). Sie kann zudem vor der Inbetriebnahme – Offline-Methodik – oder dynamisch während des Betriebs – Online-Methodik – erfolgen (Tang u. a. 2018, S. 12; Arnold 2005, S. 34).

Die Vielzahl an verfügbaren Methoden zur Parametererfassung macht die Wahl des geeigneten Verfahrens zu einer Herausforderung. Trotz der Vielzahl an modernen Invertern und deren Software in der Industrie sind oft nicht alle Parameter mit einem einzelnen Verfahren oder einer Inverter-Software messbar oder nötig (Schröder und Böcker 2021, S. 498; Odhano u. a. 2019, S. 3604). Dafür ist eine systematische Bewertung und Auswahl des Prozesses nötig – je nach Anforderungen an die jeweiligen Parameter.

In der industriellen Praxis fehlt häufig eine systematische Bewertung der vielen Parametererfassungsverfahren, was den Auswahlprozess erschwert und oft zu ineffizienten Kombinationen einzelner Verfahren oder Softwarelösungen führt. Diese Lücke hemmt die Weiterentwicklung automatisierter Inbetriebnahmeprozesse.

1.2 Zielsetzung der Arbeit

Ziel dieser Arbeit ist es, verschiedene Verfahren zur Parametererfassung elektrischer Maschinen zu identifizieren, sie zu kategorisieren, zu beschreiben und hinsichtlich ihrer Eignung für den Einsatz in Inverter-Software zu analysieren. Dabei werden Offline-, Online-Methoden und adaptive/intelligente Verfahren betrachtet. Ein weiteres Ziel ist es, zukünftige intelligente oder bereits bestehende Methoden zur Parametererfassung zu analysieren und einen Überblick zu geben.

Die Arbeit geht von den einfachsten Verfahren zu den komplexeren über und schafft eine Übersicht für die Leser über die Kombinationen von Verfahren sowie Ober- und Unterkategorisierungen der einzelnen Verfahren. Die einzelnen Verfahren werden anhand von Beispielen und bereits durchgeführten Simulationen – falls vorhanden – veranschaulicht. Inverter-Software aus der Praxis wird anhand dieser Verfahren erklärt. Ein besonderer Schwerpunkt liegt auf der

Bewertung der Verfahren in Bezug auf ihre Umsetzbarkeit in industriellen Softwarelösungen.

Die Arbeit verfolgt dabei einen theoretischen Ansatz auf Grundlage einer Literaturauswertung und marktorientierter Analyse.

1.3 Aufbau der Arbeit

Die Arbeit ist in sechs Kapitel gegliedert.

Kapitel 1 führt in das Thema ein, beschreibt die Problemstellung und formuliert das Ziel der Arbeit.

Kapitel 2 beschreibt die Funktion und Bedeutung moderner Inverter hinsichtlich der Parametererfassung, stellt die Bedeutung und Aufgabe von Inverter-Software vor und vermittelt dem Leser dadurch ein grundlegendes Wissen über den Stand der Technik.

Kapitel 3 behandelt das Hauptthema, stellt alle wichtigen Maschinenparameter und Parametererfassungsmethoden dar. Alle Methoden werden in Online-, Offline- sowie adaptive/intelligente Verfahren kategorisiert. Anwendungen und Beispiele zu allen Methoden werden gezeigt, analysiert und zusammengefasst.

Kapitel 4 widmet sich der Analyse von industriellen Inverter-Softwarelösungen. Anhand konkreter Beispiele wird dargestellt, welche Verfahren zur Parametererfassung in der Praxis vorkommen, insbesondere im Zusammenhang mit Self-Commissioning-Funktionen.

Kapitel 5 zeigt die aktuellen Entwicklungen, bestehenden Herausforderungen und zukünftigen Trends im Bereich der Parametererfassung.

Kapitel 6 fasst die wesentlichen Ergebnisse der Arbeit zusammen und gibt einen Ausblick auf mögliche Weiterentwicklungen.

2 Die Funktion und Bedeutung moderner Inverter

Inverter sind ein Oberbegriff für Stromumwandler (Michel 2008, S. 3) und stellen wichtige und essenzielle elektronische Geräte dar, die besonders häufig in modernen elektrischen Antriebssystemen zum Einsatz kommen. Je nach Anwendung werden sie auch als Frequenzumrichter, Stromrichter, Wechselrichter oder Drehrichter genannt (Schröder 2012, S. 1–2). Abbildung 1 zeigt die Ober- und Unterbegriffe von Invertern und ihre Kategorisierung. Sie wandeln den Strom um; allgemein gilt, dass sie DC in AC umwandeln, dies kann aber je nach Anwendung variieren (Mertens 2022, S. 223). Außerdem steuern sie elektrische Maschinen, indem sie die Drehzahl, das Drehmoment und die Richtung dieser Maschinen regeln (Kampker und Heimes 2024, S. 196; Mohan u. a. 2023, S. 2).

In Abbildung 2 ist die grundlegende Struktur eines Inverters dargestellt, bestehend aus Umrichter, Steuerung, elektrischer Maschine und Last, sowie deren Wechselwirkungen. Für diese Regelung sind die Parameter der elektrischen Maschine notwendig, die durch moderne Inverter bestimmt werden (Odhano 2014, S. 1).

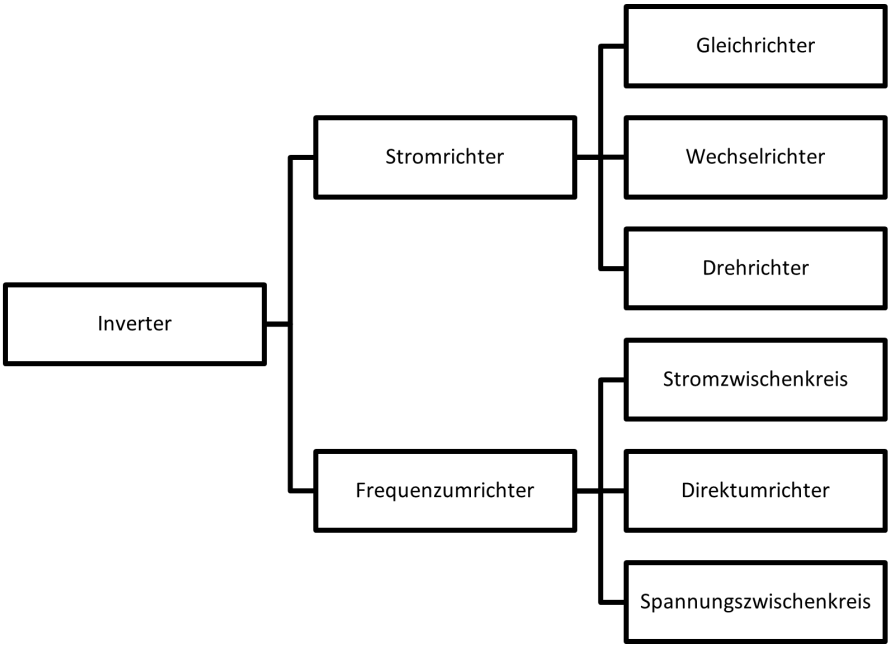

Abbildung 1: Untergliederung von Invertern nach Funktion und Aufbau

Inverter tragen maßgeblich zur Effizienz, Flexibilität und Automatisierung industrieller Anwendungen bei. Besonders in der Automatisierungstechnik, Robotik, Mobilität und Energieversorgung sind sie unverzichtbar geworden (Schröder 2012, S. V). Durch Inverter-Software, die von

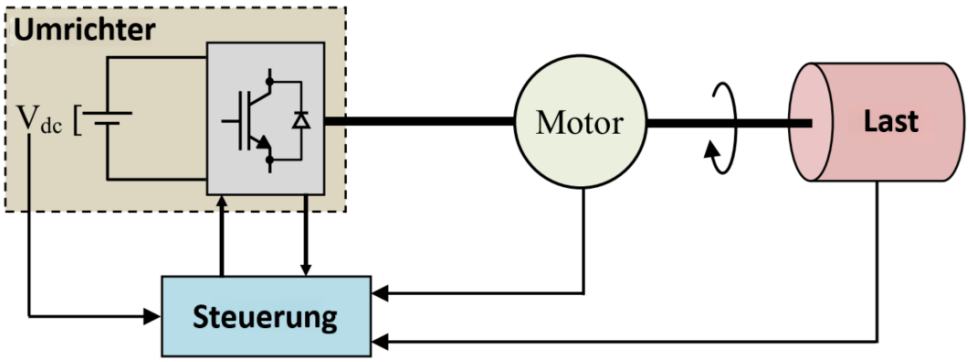

Abbildung 2: Aufbau eines elektrischen Antriebsstrangs bestehend aus Umrichter, Motor, Last und der zugehörigen Steuerung (Odhano 2014, S. 10)

vielen Herstellern heutzutage angeboten wird, wurden Inverter intelligenter und übernehmen neben den Umwandlungsaufgaben auch intelligente Regelungs- und Überwachungsaufgaben (Mertens 2022, S. 223; Mohan u. a. 2023, S. 2). Die intelligenten Inverter sind auch für die Erfassung der Motorenparameter zuständig (Odhano 2014, S. 5).

2.1 Grundlagen moderner Inverter

Die Hauptfunktion eines Inverters ist die Umwandlung von Gleichstrom – DC – in Wechselstrom – AC – (Mertens 2022, S. 223). Dies erfolgt durch leistungselektronische Komponenten wie z. B. IGBTs oder MOSFETs, welche als integrale Bestandteile moderner Inverter gelten (Schröder 2012, S. 836). Dabei wird die anliegende Gleichspannung in eine frequenz- und amplitudenvariable Wechselspannung umgesetzt. Auf diese Weise lassen sich elektrische Maschinen – z. B. Asynchron- oder Synchronmaschinen – drehzahlvariabel betreiben.

Ein typischer Inverter besteht aus drei Hauptkomponenten – In Abbildung 3 zu sehen –: (Schröder 2012, S. 836-837; Hagl 2024, S. 147-148)

- **Gleichrichter:** wandelt die Netzwechselspannung (AC) in eine Gleichspannung (DC) um.
- **Zwischenkreis:** speichert die Gleichspannung in Kondensatoren und glättet sie.
- **Wechselrichterstufe:** erzeugt mittels Pulsweitenmodulation (PWM) die gewünschte Ausgangswechselspannung.

Diese Umwandlungsprozesse ermöglichen die Regelung der Drehzahl und dadurch die Steuerung elektrischer Maschinen, die Optimierung des Wirkungsgrads und die Überwachung der Maschine.

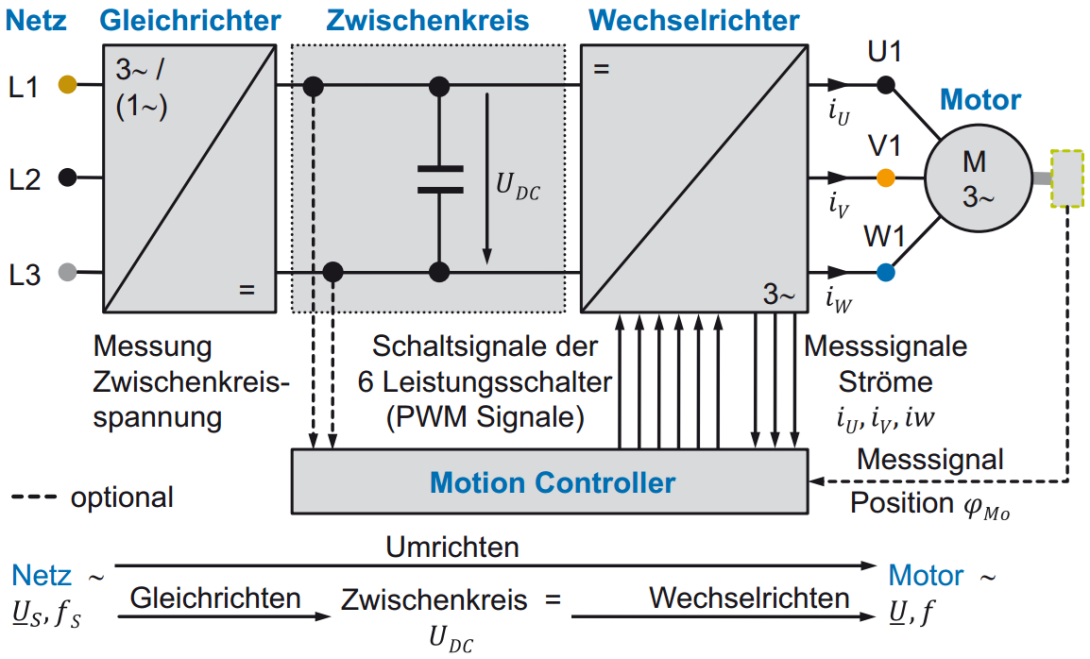

Abbildung 3: Umrichter für Drehstrommotoren (Hagl 2024, S. 148)

2.2 Rolle der Software bei Invertern in Bezug auf die Parametererfassung

Moderne Inverter verfügen über fortschrittliche Software. Neben den Hauptfunktionen eines klassischen Inverters, wie z. B. der Umwandlung elektrischer Energie, ermöglicht sie auch die intelligente Erfassung, Auswertung und Anwendung von Maschinenparametern. Diese Software ist mit den Invertern integriert und wird in der Produktion direkt von den Firmen so hergestellt (Schierling 1988, S. 287; Odhano 2014, S. 5).

Ein wesentliches Anwendungsfeld der Inverter-Software ist die Parametererfassung, auch Parameteridentifikation genannt. Dabei erfasst die Software relevante Maschinenparameter. Diese Parameter sind für die Regelung, Effizienz, Dynamik und Stabilität der elektrischen Maschine relevant (Odhano 2014, S. 1; Tang u. a. 2018, S. 1).

Die Software analysiert hierbei je nach Methode die durch Sensorik oder Strom- und Spannungsrückmeldungen erzeugten Rohdaten und leitet daraus die Maschinenparameter ab (Schierling 1988, S. 287). Die Software verfügt über unterschiedliche Parametererfassungsmethoden, die sowohl vor dem Betrieb – Offline-Betrieb – als auch während des Betriebs – Online-Betrieb – dynamisch die Parameter der elektrischen Maschine erfassen und die Maschine entsprechend anpassen (Odhano u. a. 2019, S. 3604–3606).

Trotz des Fortschritts der Softwarelösungen können nicht alle Parameter der Maschine mit nur einer Methode erfasst werden. Die fehlende Übersicht über die zahlreichen Methoden und die Auswahl der korrekten und effizientesten Lösung gestaltet sich oft als kompliziert (Schröder

und Böcker 2021, S. 498). Häufig werden aus diesem Grund mehrere Methoden kombiniert und automatisiert.

Die Inverter-Software ist somit ein wichtiger Bestandteil der intelligenten Inbetriebnahme, der Regelung und der überwachten Prozessführung bei elektrischen Maschinen in industriellen Anwendungen.

3 Parametererfassung: Wichtige Maschinenparameter und Methoden

Die präzise Erfassung elektrischer Maschinenparameter bildet die Grundlage für viele Prozesse in modernen Antriebssystemen. Durch die Ermittlung und Verarbeitung/Analyse der Maschinenparameter werden die Regelung, Steuerung, Überwachung und dynamische Optimierung elektrischer Maschinen ermöglicht (Schröder und Böcker 2021, S. 498). Durch moderne Inverter, die mit Software integriert sind – wie auch in Kapitel 2.2 beschrieben –, können diese Maschinenparameter durch mehrere Methoden gemessen und präzise abgeleitet bzw. erfasst werden.

3.1 Zielsetzung und Rolle der Parametererfassung

Die Parametererfassung einer elektrischen Maschine ist die Grundlage zur Erstellung eines regelungstechnischen Modells. Die Regelung und Steuerung der Maschine werden auf Basis dieses Modells durchgeführt (Schröder und Böcker 2021, S. 498). Steuerstrategien wie die feldorientierte Regelung – FOC – greifen auf dieses Modell zu (Hagl 2024, S. 291; Kania u. a. 2011, S. 1). Neben diesen Funktionen dient die Parametererfassung der Überwachung, Optimierung und Stabilisierung der Maschine (Schröder und Böcker 2021, S. 498; Mohan u. a. 2023, S. 2; Mertens 2022, S. 223).

Die Hauptziele der Parametererfassung sind:

- Die effiziente Regelung elektrischer Maschinen
- Bereitstellung einer Datenbasis für die Parametrierung bei der Inbetriebnahme
- Schaffung einer stabilen und effizienten Regelung
- Grundlage für Überwachungssysteme

Insbesondere die korrekte und effiziente Regelung hängt stark von präzise und korrekt erfassten Maschinenparametern ab.

3.2 Zentrale Maschinenparameter und deren Einflussgrößen

Die Maschinenparameter dienen als Grundlage für die mathematische Beschreibung des Maschinenverhaltens und sind für die Erstellung eines regelungstechnischen Modells der Maschine

notwendig, wie bereits in Kapitel 3.1 beschrieben. Dabei werden Parameter in elektrische und mechanische unterschieden. Elektrische Parameter werden aus elektrischen Messungen oder Modellen bestimmt und beschreiben den elektrischen Teil der Maschine. Mechanische Parameter hingegen beschreiben die Bewegung und das Drehmoment der Maschine. Sie wirken auf das dynamische Verhalten des Antriebs. Tabelle 1 dient als Übersicht über alle Maschinenparameter, die in dieser Arbeit vorkommen und für diese Arbeit relevant sind, sowie deren Formelzeichen und Art.

Tabelle 1: Übersicht der Maschinenparameter und zugehörige Formelzeichen

Parameter	**Formelzeichen**	**Art**
Nennspannung	U_N	Elektrisch
Nennstrom	I_N	Elektrisch
Nennfrequenz	f_N	Elektrisch
Statorwiderstand	R_s	Elektrisch
Rotorwiderstand	R_r	Elektrisch
Eisenverlustwiderstand	R_{Fe}	Elektrisch
Reaktanz	X	Elektrisch
Magnetisierungsinduktivität	L_m	Elektrisch
Statorinduktivität	L_s	Elektrisch
Rotorinduktivität	L_r	Elektrisch
Leckinduktivität	L_σ	Elektrisch
Statorfluss	Ψ_s	Elektrisch
Rotorfluss	Ψ_r	Elektrisch
Rotorzeitkonstante	T_r	Elektrisch
Thermische Zeitkonstante	τ_{th}	Elektrisch
Kupferverluste	P_{cu}	Elektrisch
Eisenverluste	P_{fe}	Elektrisch
Nenndrehzahl	n_N	Mechanisch
Nennleistung	P_N	Mechanisch
Polpaarzahl	p	Mechanisch
Trägheitsmoment	J	Mechanisch
Drehmomentkonstante	K_t	Mechanisch
Momentenbezugskonstante	c_T	Mechanisch
Mechanische Drehzahl	ω_r	Mechanisch
Rotordrehzahl	ω_r	Mechanisch
Rotorlage	Θ_r	Mechanisch
Viskose Reibung	B	Mechanisch
Restmagnetisierung	Φ_{res}	Mechanisch
Drehmoment	M	Mechanisch

Parameter	Formelzeichen	Art
Elektromagnetisches Drehmoment	T_e	Mechanisch
Maximales Drehmoment	$M_{t(max)}$	Mechanisch
Sättigungsverhalten	Modellabhängig	Modellabhängig

Nicht alle Maschinenparameter kommen häufig zum Einsatz und sind relevant für jeden Zweck (Odhano u. a. 2019, S. 3604; Tang u. a. 2018, S. 2). In der Praxis konzentriert sich die Invertersoftware auf wesentliche Parameter, die in nahezu allen Anwendungen relevant sind. Daher konzentriert sich der Inverter insbesondere auf die Parameter, die das elektrische, magnetische und mechanische Verhalten einer Maschine beeinflussen (Odhano u. a. 2019, S. 3603).

Im Folgenden Abschnitt werden die Parameter definiert, die die größte Rolle für die Modellbildung, Steuerung sowie Überwachung elektrischer Maschinen spielen:

- Statorwiderstand: Beeinflusst Spannungsverluste und das thermische Verhalten. Wichtig für temperaturabhängige Korrekturen und die Stromregelung im Betrieb (Odhano u. a. 2019, S. 3604; Schierling 1988, S. 287; Tang u. a. 2018, S. 12; Hagl 2024, S. 66).
- Rotorwiderstand: Der Rotorwiderstand beeinflusst das Schlupfverhalten bei Asynchronmaschinen und ist notwendig zur Berechnung des Rotorflusses. Dient als Grundlage für die FOC (Fischer und Nolle 2022, S. 262; Odhano u. a. 2019, S. 3604; Schierling 1988, S. 287; Tang u. a. 2018, S. 12).
- Magnetisierungsinduktivität: Die Kopplung zwischen Stator- und Rotorfeld wird durch die Magnetisierungsinduktivität beschrieben und bestimmt den magnetischen Fluss – der wiederum für die Berechnung von Moment und Drehzahl benötigt wird (Odhano u. a. 2019, S. 3604; Tang u. a. 2018, S. 12).
- Polpaarzahl: Die Polpaarzahl beschreibt das Verhältnis zwischen elektrischer und mechanischer Drehzahl. Sie ist relevant für die drehzahlabhängige Regelung (Fischer und Nolle 2022, S. 267).
- Trägheitsmoment: Beschreibt das dynamische Verhalten der Maschine bei Beschleunigung und Verzögerung. Es ist besonders für die Momentenregelung wichtig.
- Drehmomentkonstante: Verbindet den Strom mit dem mechanischen Moment. Dadurch kann das erzeugte Moment direkt aus elektrischen Größen berechnet werden. Wichtig für die Leistungsregelung und Momentbegrenzung (Hagl 2024, S. 166).
- Rotor-Zeitkonstante: Ergibt sich aus dem Verhältnis von Rotorinduktivität zu Rotorwiderstand – Formel 1 –. Bestimmt, wie schnell sich der Rotorfluss an veränderte Betriebsbedingungen anpasst. Die Rotor-Zeitkonstante hat einen direkten Einfluss auf die Stabilität

und Genauigkeit für FOC (Schierling 1988, S. 287; Tang u. a. 2018, S. 12; Kaźmierkowski u. a. 2002, S. 184).

$$T_r = \frac{L_r}{R_r} \tag{1}$$

- Rotorfluss: Der Rotorfluss ist die zentrale Größe in der FOC und steht in direktem Zusammenhang mit der Momentenbildung. Der Rotorfluss ist die wichtigste Zustandsgröße in Flussbeobachtern (Schröder und Böcker 2021, S. 1125).
- Statorfluss: Der Statorfluss ist die Summe, der im Stator erzeugten, magnetischen Flüsse. Wichtig für die FOC (Schröder und Böcker 2021, S. 426).
- Drehmoment: Das Moment ergibt sich aus dem Produkt von Fluss und Strom und ist das wichtigste Ergebnis der Stromregelung. Es wird je nach Regelung direkt oder indirekt beeinflusst (Schröder und Böcker 2021, S. 438; Schröder und Böcker 2021, S. 701).

Die folgenden Parameter werden für spezielle Anwendungen ermittelt und kommen in der Praxis selten vor:

- Leckinduktivität: Beeinflusst das EMV-Verhalten und wird ins Modell aufgenommen, nur bei Berücksichtigung von Eisenverlusten (Odhano u. a. 2019, S. 3604; Tang u. a. 2018, S. 12; Kaźmierkowski u. a. 2002, S. 271).
- Stator- und Rotorinduktivität: Für detailliertere Modelle relevant. Berechnet den verketteten Fluss und das Momentverhalten. – z. B. Simulationen – (Odhano u. a. 2019, S. 3604; Schierling 1988, S. 287).
- Kupferverluste: Wichtig für die Verlustabschätzung (Hagl 2024, S. 66).
- Eisenverluste: Wichtig für die Verlustabschätzung (Odhano u. a. 2019, S. 3604; Hagl 2024, S. 66).
- Sättigungsverhalten: Dient zur Modellierung nichtlinearer Flussverläufe (Mrugowsky 2015, S. 72).
- Thermische Zeitkonstanten: Für Temperaturmodelle bei sensorloser Überwachung (Hagl 2024, S. 68).
- Viskose Reibung: Bei präzisen Antriebsmodellen – z. B. Robotik – (Schröder und Böcker 2021, S. 1315).

Insgesamt zeigt sich, dass die elektrisch, magnetisch und mechanisch relevanten Parameter als Basis für die Modellbildung, Regelung und Überwachung elektrischer Maschinen dienen.

Die Wahl der erfassten Parameter hängt von der jeweiligen Anwendung und den eingesetzten Erfassungsmethoden ab, auf die im Folgenden Kapitel eingegangen wird.

3.3 Aktuelle Methoden der Parametererfassung

Für die Erfassung der Maschinenparameter gibt es viele Methoden. Diese Methoden werden je nach dem Zeitpunkt der Anwendung – vor der Inbetriebnahme (Offline-Methoden) sowie während des Betriebs (Online-Methoden) – kategorisiert, wie bereits in Kapitel 1.1 beschrieben. Zudem kommen noch adaptive/intelligente Methoden zum Einsatz als eine eigene Kategorie und lernen adaptiv (Bonifacio u. a. 2018, S. 1; Li Liu u. a. 2007, S. 2955), passen sich an Zustände an durch die Nutzung von Machine Learning oder KI (Beyer 2018, S. 97). Eine grafische Darstellung der grundlegenden Untergliederung der Verfahren ist in Abbildung 4 zu sehen. Diese Methoden sind sowohl einzeln als auch kombiniert anwendbar. Die Kombination von mehreren Methoden schafft neue, automatisierte Methoden. Ein konkretes und in der Industrie beliebtes Beispiel dafür ist das Self-Commissioning-Verfahren (Odhano 2014, S. 1; Kania u. a. 2011, S. 1–2).

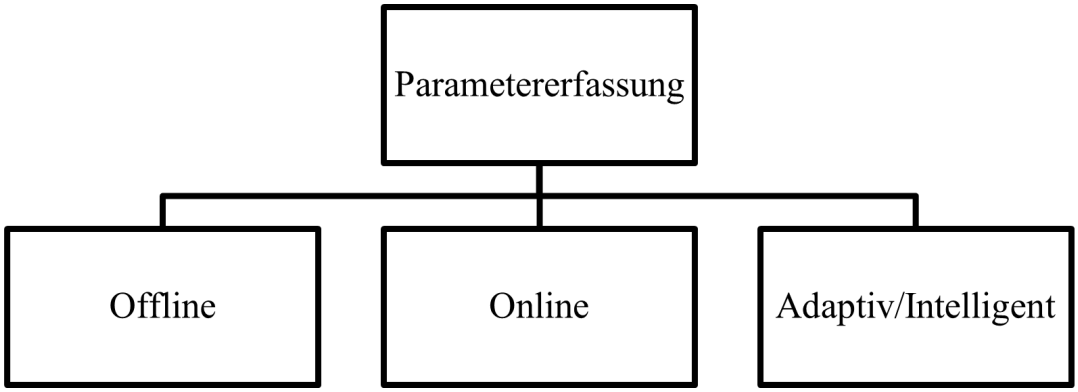

Abbildung 4: Klassifikation der Parametererfassungsmethoden für elektrische Maschinen

Moderne Inverter-Softwarelösungen integrieren diese Methoden als kombinierte und automatisierte Verfahren. Statt alle Methoden einzeln durchzuführen, werden die essenziellen Maschinenparameter, wie bereits im Kapitel 3.2 beschrieben, automatisiert durch ein Verfahren ermittelt. Zudem werden je nach Anwendung, Bedarf und Bedingungen auch einzelne, nicht-automatisierte Verfahren, insbesondere bei der Online-Parametererfassung, eingesetzt. Diese sind dynamische Algorithmen, die während des Betriebs ausgeführt werden, um Parameterverschiebungen durch Temperatur, Alterung oder Lastwechsel automatisch zu kompensieren (Karanayil u. a. 2005, S. 772; Tang u. a. 2018, S. 2).

Ein ausführlicher Überblick über diese Methoden ist in Tabelle 2 zu sehen. Dort sind die Verfahren als Offline, Online oder Adaptiv/Intelligent kategorisiert und nach wachsender Komplexität sortiert. Außerdem ist in der Tabelle zu sehen, welche Parameter von der jeweiligen Methode erfasst werden. Diese Übersicht dient als Orientierung für die Wahl einer geeigneten und mög-

lichst unkomplexen Methode zur Erfassung bestimmter Parameter sowie als Grundwissen für die folgenden Kapitel. Die einzelnen Verfahren werden im Anschluss jeweils mit Funktionsweise, Anwendungen und Quellen vorgestellt und analysiert.

Tabelle 2: Übersicht von Methoden zur Maschinenparametererfassung mit zugehörigen Parametern

Kategorie	**Verfahren**	**Erfasste Parameter**
Offline	Typenschildbasierte Abschätzung	R_s, R_r, L_m, c_T, J
Offline	Gleichstromversuch	R_s
Offline	Leerlaufversuch	L_m, R_{Fe}
Offline	Kurzschlussversuch	R_r, X_σ
Offline	Rampentest / Low-Speed Test	J
Offline	Standstill Identification	R_r, R_s, X_σ
Offline	Least Squares*	R_r, L_m, L_σ
Offline	Self-Commissioning	Alle Parameter der zuvor genannten Einzelverfahren
Online	DC-Signal Injection	R_s
Online	HF Signal Injection	L_σ, Θ_r
Online	Rotating Voltage Injection	Θ_r
Online	Pulsinjektion	Θ_r
Online	Luenberger-Observer	Θ_r, ω_r
Online	Sliding Mode Observer	Θ_r, ω_r
Online	Recursive Least Squares*	Θ_r, ω_r
Online	Direct Flux and Torque Estimation	Ψ_r, T_e
Online	MRAS	Θ_r, ω_r
Online	Extended Kalman Filter (EKF)*	Θ_r, ω_r
Adaptiv/Intelligent	Fuzzy Logic Controller*	R_s
Adaptiv/Intelligent	Support Vector Machines*	Je nach Trainingsdaten
Adaptiv/Intelligent	Genetic Algorithms*	R_s, R_r, L_s
Adaptiv/Intelligent	GPSO/PSO*	R_s, R_r, L_s
Adaptiv/Intelligent	Differential Evolution*	R_s, L_σ
Adaptiv/Intelligent	Neuronale Netze*	Je nach Trainingsdaten

Verfahren mit * sind mathematische Auswertealgorithmen und keine eigenständigen Messmethoden.

In der Praxis sind insbesondere Offline-Methoden direkt in die Gerätesoftware integriert mit Unterstützung von Online-Verfahren. Industrielle Inverter verwenden solche Methoden als eigene integrierte Verfahren. Einige werden nur einmal vor der Inbetriebnahme ausgeführt – Offline-Methoden – (Schierling 1988, S. 287), andere wiederum laufen fortlaufend mit – Online-Methoden – (Schierling 1988, S. 1; Odhano u. a. 2019, S. 3604; Arnold 2005, S. 34-35; Tang u. a. 2018, S. 5). Damit sind Methoden zur Parametererfassung nicht nur theoretische Verfahren, sondern ein fester Bestandteil kommerzieller Inverter-Softwareprodukte.

3.4 Offline-Parametererfassung

Die Offline-Methoden werden vor der Inbetriebnahme einer elektrischen Maschine durchgeführt, d. h., wenn die Maschine nicht unter Last steht (Odhano u. a. 2019, S. 3604–3606; Tang u. a. 2018, S. 3). Diese Methoden können sowohl einzeln durch Prüfstände oder Messgeräte durchgeführt werden als auch durch einen Inverter mit integrierter Offline-Parametererfassungssoftware (Tang u. a. 2018, S. 3). Je nach Zweck oder Anwendung können die parametrierten Daten entweder direkt angewendet oder durch Online- sowie intelligente Methoden verfeinert werden.

Große Inverterhersteller wie Siemens, ABB oder Danfoss haben auf dem Markt zahlreiche moderne Inverterprodukte, die bereits automatisierte Offline-Methoden als Software in die Inverter integriert haben und somit dem Nutzer die einzelnen Tests ersparen. Diese werden in Kapitel 4 behandelt.

Offline-Methoden sind einfach umzusetzen und basieren auf simplen Mess- und Rechenmethoden, da sie nur statische Parameter erfassen und nur einmal durchgeführt werden müssen. Aus diesem Grund eignen sie sich hervorragend als schnelle Erstinbetriebnahmemethode, wenn nur die essenziellen Maschinenparameter erfasst werden müssen und keine speziellen Anforderungen bestehen.

Die nachfolgenden Abschnitte zeigen die wichtigsten Offline-Verfahren im Detail – von einfacheren zu den komplexeren aufgebaut – und zeigen, wie das Self-Commissioning-Verfahren die einzelnen Methoden kombiniert und automatisiert durchführt. Außerdem werden die einzelnen Maschinenparameter mit den Methoden verknüpft, indem gezeigt wird, wie durch die jeweilige Methode auf die zugehörigen Parameter zugegriffen wird.

3.4.1 Typenschildbasierte Abschätzung

Die typenschildbasierte Abschätzung ist die einfachste und schnellste Offline-Methode zur Parametererfassung einer elektrischen Maschine. Durch die Herstellerangaben auf dem Maschinentypenschild lassen sich mehrere grundlegende Maschinenparameter ableiten. Dabei werden keine physikalischen Messungen an der Maschine durchgeführt (Schröder und Böcker 2021, S. 498). Die Inverter-Software entnimmt die Daten entweder direkt vom Typenschild oder die

Daten werden vom Benutzer manuell eingegeben. In Abbildung 5 ist ein Typenschild eines 2,2 kW-Induktionsmotors zu sehen. Die folgenden Daten lassen sich daraus ablesen: Nennspannung U_N (400V), Nennstrom I_N (5,08A), Nennfrequenz f_N (50Hz), Nenndrehzahl n_N (1400 min^{-1}), Nennleistung P_N (2,2kW); die Polpaarzahl p kann aus diesen Daten einfach berechnet werden. Auch andere Typenschilder enthalten in der Regel dieselben standardisierten Angaben (Mrugowsky 2015, S. 161–162). Diese Größen dienen anschließend zur Ermittlung weiterer Maschinenparameter.



Abbildung 5: Typenschild eines 2.2 kW Induktionsmotors (Odhano 2014, S. 54)

Aus diesen Werten lassen sich Maschinenparameter wie der Statorwiderstand R_s, der Rotorwiderstand R_r, die Magnetisierungsinduktivität L_m, die Momentenbezugskonstante c_T, das Massenträgheitsmoment J – über Abschätzungstabellen – oder die Synchronfrequenz ableiten bzw. schätzen oder durch zusätzliche Messverfahren bestimmen (Mrugowsky 2015, S. 166, 240–244; Odhano 2014, S. 56), wie bereits in Tabelle 2 gezeigt.

Ein Inverter kann aus diesen Daten z. B. die Motorkennlinie berechnen oder den Regelalgorithmus vorbereiten – dies ist jedoch nicht immer der Fall und in der Fachliteratur unüblich, da die erfassten Parameter unpräzise sind und mit hohen Abweichungen zu rechnen ist (Odhano 2014, S. 53, 56; Schröder und Böcker 2021, S. 498). Die angegebenen Daten und die daraus bestimmten Parameter hängen stark von der Maschinenart und dem Hersteller ab.

Die typenschildbasierte Abschätzung ist die einfachste Funktion eines Inverters zur Parameterbestimmung. Sie eignet sich besonders für einfache Anwendungen oder als Vorbereitung auf präzisere und aufwendigere Verfahren wie z. B. Self-Commissioning oder Online-Methoden. Für die Regelung wird sie nicht bzw. nur selten verwendet. Bei dieser Methode ist häufig mit

hohen Abweichungen bzw. großen Fehleranteilen zu rechnen (Odhano 2014, S. 53, 56; Schröder und Böcker 2021, S. 498).

3.4.2 Gleichstromversuch

Der Gleichstromversuch ist eine klassische Offline-Methode (Tang u. a. 2018, S. 12; Arnold 2005, S. 36). Er basiert auf dem Ohm'schen Gesetz und wird durchgeführt, indem eine Gleichspannung an zwei Phasen der Ständerwicklung einer Drehstrommaschine angelegt wird, während die dritte Phase offen bleibt (Mrugowsky 2015, S. 153; Nalakath et al. 2021, S. 1). Der Statorwiderstand R_s lässt sich durch diese Methode ableiten und ist der dabei erfasste Parameter (Tang u. a. 2018, S. 12; Schröder und Böcker 2021, S. 504). Der Widerstand ergibt sich aus dem gemessenen Strom nach Formel 2:

$$R_s = \frac{U_{DC}}{I_{DC}} \tag{2}$$

(Mrugowsky 2015, S. 155; Schröder und Böcker 2021, S. 504)

Dabei bezeichnet U_{DC} die angelegte Gleichspannung zwischen zwei Anschlussklemmen der Ständerwicklung, und I_{DC} ist der dabei gemessene Gleichstrom, der durch zwei in Reihe geschaltete Stränge fließt. Da bei der Messung der ermittelte Widerstand aus zwei Statorwicklungen besteht, ergibt sich der tatsächliche Widerstand zu Formel 3:

$$R_s = \frac{1}{2}R \tag{3}$$

(Mrugowsky 2015, S. 155)

Der Gleichstromversuch ist einfach umzusetzen – es werden keine Wechselspannungen oder komplexen Aufbauten benötigt. Der Versuch wird im Stillstand durchgeführt (Nalakath et al. 2021, S. 1) – laufender Betrieb wäre möglich, wird jedoch nicht bevorzugt –, um induktive Effekte zu vermeiden (Schröder und Böcker 2021, S. 504). Moderne Inverter-Software aus der Industrie führen diesen Test automatisiert im Rahmen von Self-Commissioning-Verfahren durch (Nalakath et al. 2021, S. 1; Siemens AG 2012, S. 115; ABB Group 2013, S. 306; Danfoss Editron 2025b, S. 1–2). Die Software übernimmt dabei die Ansteuerung, Messung und Auswertung der Gleichstromreaktion. Abbildung 6 zeigt das Ersatzschaltbild einer elektrischen Maschine bei Gleichstromspeisung.

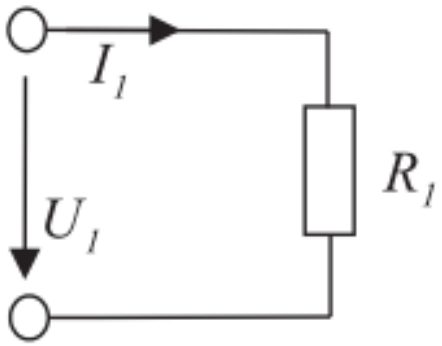

Abbildung 6: Ersatzschaltbild bei Gleichstromspeisung(Schröder und Böcker 2021, S. 504)

Der Statorwiderstand R_s – ermittelt aus dem Gleichstromversuch – wird für die Regelung der elektrischen Maschine – z. B. bei der feldorientierten Regelung (FOC) – verwendet. Der Versuch bietet eine hohe Genauigkeit bei gleichzeitig geringer Komplexität.

3.4.3 Leerlaufversuch

Der Leerlaufversuch ist eine klassische Offline-Methode (Schröder und Böcker 2021, S. 501–502; Odhano u. a. 2019, S. 3605; Arnold 2005, S. 36). Er wird im stationären Betrieb einer elektrischen Maschine durchgeführt – die Maschine wird ohne Last betrieben und läuft nahezu synchron, während der Schlupf s annähernd null ist (Schröder und Böcker 2021, S. 502–503). Dabei erfasst der Inverter die Hauptfeldinduktivität L_m – über die Reaktanz X_h ermittelt – sowie den Eisenverlustwiderstand. Aus der gemessenen Impedanz $Z_L(j\omega)$ – Formel 4 – kann der Eisenverlustwiderstand R_{Fe} – nach Formel 5 – berechnet werden. Der Realteil der Impedanz wird verwendet und um den ohmschen Widerstand R_1 korrigiert. Anschließend wird die Hauptfeldreaktanz X_h bestimmt – nach Formel 6 –, indem der Imaginärteil der Impedanz und die zuvor berechneten Größen berücksichtigt werden. X_h ist direkt proportional zur Hauptfeldinduktivität L_m.

$$Z_L(j\omega) = R_1 + jX_{\sigma 1} + \frac{R_{Fe} \cdot jX_h}{R_{Fe} + jX_h} \tag{4}$$

$$R_{Fe} = \frac{(\Re\{Z_L(j\omega)\} - R_1)^2 + (\Im\{Z_L(j\omega)\} - X_{\sigma 1})^2}{\Re\{Z_L(j\omega)\} - R_1} \tag{5}$$

$$X_h = \frac{(\Re\{Z_L(j\omega)\} - R_1)^2 + (\Im\{Z_L(j\omega)\} - X_{\sigma 1})^2}{\Im\{Z_L(j\omega)\} - X_{\sigma 1}} \tag{6}$$

(Schröder und Böcker 2021, S. 505)

Die Ständerwicklung der Maschine wird mit Nennspannung U_N gespeist, während keine Last anliegt. Der dabei aufgenommene Strom wird durch das magnetische Verhalten des Maschinenkerns beeinflusst. Die gemessene Leerlaufleistung setzt sich hauptsächlich aus Ummagnetisierungsverlusten, Kupferverlusten im Ständer und mechanischen Verlusten zusammen (Schröder und Böcker 2021, S. 501). Abbildung 7 zeigt das Ersatzschaltbild einer elektrischen Maschine im Leerlauf.

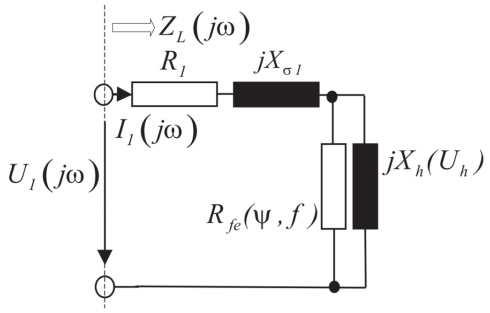

Abbildung 7: Ersatzschaltbild der elektrsichen Maschine im Leerlauf (Schröder und Böcker 2021, S. 506)

Moderne Inverterlösungen aus der Industrie integrieren diesen Versuch als Teil des Self-Commissioning-Prozesses – d. h. er wird automatisiert durchgeführt (Kania u. a. 2011, S. 2). Dabei erfolgen die Spannungsanregung und Strommessung automatisch. Die ermittelten Parameter fließen direkt in das Maschinenmodell ein und werden bei der Regelung – besonders bei der feldorientierten Regelung (FOC) – verwendet. Kleinere Aufbauten sowie Maschinen führen den Versuch ungenauer durch, insbesondere aufgrund erhöhter mechanischer Verluste und Reibmomente. Dafür wird eine Synchronanregung verwendet, um den Leerlauf unter konstanten magnetischen Bedingungen zu gewährleisten (Schröder und Böcker 2021, S. 503).

3.4.4 Kurzschlussversuch

Der Kurzschlussversuch ist eine Offline-Methode zur Bestimmung elektrischer Parameter einer elektrischen Maschine (Arnold 2005, S. 36; Schröder und Böcker 2021, S. 504). Die Methode wurde früher auch Blockierprüfung genannt und wurde zur Qualitätskontrolle der elektrischen Maschine eingesetzt (McElveen und Melfi 2015, S. 1). Heutzutage wird sie jedoch als Parametererfassungsmethode bei modernen Invertern unter dem Namen Kurzschlussversuch verwendet.

Die Maschine wird bei blockiertem Rotor – Schlupf $s = 1$ – mit reduzierter Wechselspannung betrieben. Strom I, Spannung U und Leistung P werden dabei gemessen, und der Rotorwiderstand R_r sowie die Streureaktanz X werden bestimmt (Schröder und Böcker 2021, S. 504–505).

Der Kurzschlusszustand kann im Stillstand vereinfacht betrachtet werden, da die gesamte aufgenommene Leistung nahezu ausschließlich aus Kupferverlusten besteht. Ummagnetisierungsverluste und mechanische Verluste sind in diesem Zustand vernachlässigbar (Schröder und Böcker

2021, S. 503).

Aus der Eingangsimpedanz lässt sich die Kurzschlussimpedanz $Z_K(j\omega)$ ermitteln. Sie erlaubt es, mit einem vereinfachten Ersatzschaltbild die Streureaktanz – aus Formel 7 – sowie den Rotorwiderstand R_r zu bestimmen.

Die komplexe Impedanz Z_K, die im Kurzschlussversuch gemessen wird, enthält im Ersatzschaltbild den Ständerwiderstand R_s, den Rotorwiderstand R_r sowie die Streureaktanzen beider Seiten. Die Streureaktanzen X_σ werden typischerweise als gleich angenommen. Daraus ergibt sich die Formel 8. Die reale Komponente der Impedanz $\Re\{Z_K\}$ ergibt sich aus der gemessenen Wirkleistung und enthält sowohl R_s als auch R_r:

$$X_{\sigma 1} = X_{\sigma 2} \approx 0,5 \cdot X_K \tag{7}$$

(Schröder und Böcker 2021, S. 504)

Dabei muss der Statorwiderstand R_s zuvor über den Gleichstromversuch bestimmt worden sein:

$$R_r = \Re\{Z_K\} - R_s \tag{8}$$

(Schröder und Böcker 2021, S. 505)

Genau dafür sind moderne Inverter-Softwares entwickelt worden. Bei modernen Invertern sind sowohl der Gleichstromversuch als auch der Kurzschlussversuch Teil des automatisierten Self-Commissioning-Verfahrens (Kania u. a. 2011, S. 2). Somit kann ein Verfahren die benötigten Parameter für das nächste Verfahren bereitstellen und automatisiert weiterleiten.

Der Kurzschlussversuch ist besonders einfach umsetzbar, da keine Drehzahlerfassung notwendig ist. Bei Maschinen mit Kurzschlussläufer können Stromverdrängungseffekte im Läufer zu höheren Scheinwiderständen und somit zu leichten Überschätzungen von R_r führen (Schröder und Böcker 2021, S. 503).

3.4.5 Rampentest/Low-Speed Test

Der Rampentest – auch als Low-Speed-Test bezeichnet – ist eine moderne und optionale Offline-Methode zur Erfassung mechanischer Maschinenparameter (Odhano u. a. 2019, S. 3606; K. Liu und Z. Zhu 2017, S. 1). Der Test wird vor der Inbetriebnahme durchgeführt. Bei der Durchführung des Tests läuft der Motor jedoch mit niedriger Drehzahl (K. Liu und Z. Zhu 2017,

S. 2). Der wichtigste erfasste mechanische Hauptparameter ist das Massenträgheitsmoment J (K. Liu und Z. Zhu 2017, S. 1–2, 7).

Die Maschine erhält einen definierten Strom- oder Momentenimpuls, der zur Bewegung führt, und bestimmt über das Gesetz des Massenträgheitsmoments den Parameter J durch die erzeugte niedrige Drehzahl. Die Drehzahlverläufe werden von der Inverter-Software aufgenommen, abgeleitet und anschließend zur Berechnung von J verwendet (K. Liu und Z. Zhu 2017, S. 3).

Die Gleichung in Formel 9 beschreibt das Drehmomentgleichgewicht der Maschine. Auf der linken Seite steht das Produkt aus dem Massenträgheitsmoment J und der zeitlichen Ableitung der Drehzahl – also der Winkelbeschleunigung. Auf der rechten Seite befindet sich das elektromagnetische Moment, von dem die Gegenmomente und die Reibmomente $F \cdot \omega_r$ abgezogen werden. Daraus kann das Massenträgheitsmoment berechnet werden – aus dem gemessenen Drehzahlverlauf ω_r und der Differenz der wirkenden Drehmomente.

$$J\frac{d\omega_r}{dt} = T_e - F \cdot \omega_r - T_m \tag{9}$$

(K. Liu und Z. Zhu 2017, S. 2)

Es gibt keine eindeutige Quelle, die zeigt, dass der Rampentest Teil eines automatisierten Verfahrens – z. B. des Self-Commissioning – ist. Allerdings wird er in einigen Quellen erwähnt, sodass davon ausgegangen werden kann, dass er indirekt Teil des Self-Commissioning-Verfahrens in modernen Invertern ist (Odhano u. a. 2019, S. 3606). Das heißt, der Rampentest gehört zwar zum Self-Commissioning, ist aber nicht Teil des vollautomatisierten Prozesses. Der Rampentest kann separat im Rahmen des Self-Commissioning-Verfahrens ausgeführt werden – nur bei Bedarf. Die Messung erfolgt auch hier bei sehr niedrigen Drehzahlen, um Reibungseinflüsse gering zu halten.

Somit ist der Rampentest mit mittlerem Aufwand verbunden und wird in modernen Invertern automatisiert, aber separat durchgeführt. Die Ermittlung des Massenträgheitsmoments J geschieht mit hoher Genauigkeit. Die Methode ist jedoch sensibel gegenüber Reibmomenten und Modellabweichungen. Der Rampentest eignet sich besonders für industrielle Self-Commissioning-Prozesse – separat –.

3.4.6 Standstill Identification

Die Standstill Identification ist eine moderne Offline-Methode – Oberkategorie – zur Erfassung elektrischer Maschinenparameter im Stillstand – d. h. bei blockiertem Rotor – (Odhano u. a. 2019, S. 3604; Arnold 2005, S. 38). Durch diese Methode werden der Statorwiderstand R_s, der Rotorwiderstand R_r sowie die Streureaktanz X_σ bestimmt.. Diese Parameter entsprechen

den insgesamt erfassten Größen aus den einzelnen Verfahren im Stillstand – Gleichstrom- und Kurzschlussversuch – und stellen keine neuen Größen dar. Konkret besteht die Standstill Identification aus einer Kombination des Gleichstromversuchs und des Kurzschlussversuchs, wie sie auch in den Kapiteln 3.4.2 und 3.4.4 beschrieben sind und in Abbildung 8 dargestellt werden.

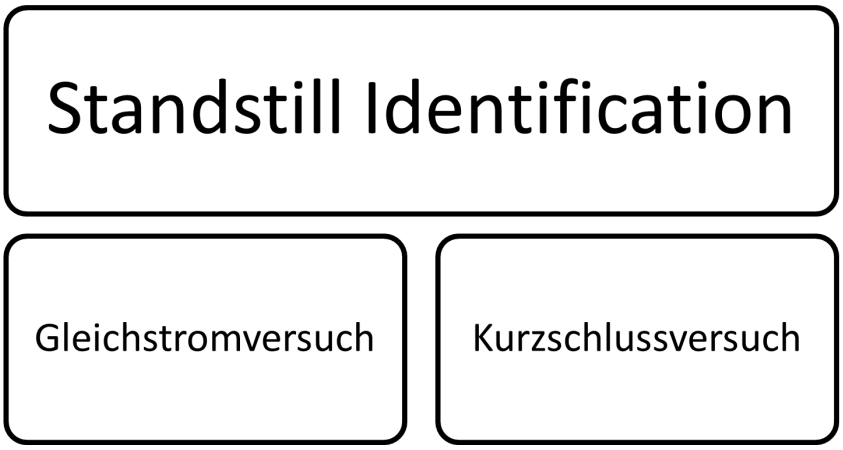

Abbildung 8: Standstill Identification, bestehend aus Gleichstromversuch und Kurzschlussversuch

Sie ist ein Oberbegriff für alle klassischen sowie in moderner Invertersoftware verwendeten Verfahren, die bei blockiertem Rotor – also im Stillstand – durchgeführt werden (Schröder und Böcker 2021, S. 501–502). Unter Standstill Identification versteht man dabei sowohl die Anwendung einzelner Methoden als auch die Kombination mehrerer Verfahren (Arnold 2005, S. 38–39), wie sie in modernen Invertern typischerweise als Teil des Self-Commissioning-Verfahrens automatisch ausgeführt werden.

Moderne Inverter aus der Industrie führen diese Methode als Teil des Self-Commissioning-Verfahrens automatisiert durch (Siemens AG 2016, S. 235; ABB Group 2013, S. 306; Danfoss Editron 2025b, S. 1–2). Die Durchführung dieser Methode ist auch einzeln als Prüfmethode oder Experiment möglich, was jedoch in industrieller Hinsicht keine Bedeutung hat.

Die Standstill Identification ist mechanisch und messtechnisch gesehen mit geringem Aufwand verbunden. Es sind keine Bewegung, keine Lastwechsel und kein externer Versuchsaufbau notwendig (Schröder und Böcker 2021, S. 519). Dennoch sind wichtige Maschinenparameter präzise erfassbar.

Trotzdem können magnetische Sättigung und Stromverdrängung im Rotor zu Abweichungen in den Ergebnissen führen. Aus diesem Grund wird die Methode – je nach Komplexität und elektrischer Maschine – mit ergänzenden Verfahren kombiniert.

3.4.7 Least Squares (als Auswertemethode)

Das Least-Squares-Verfahren ist keine Methode zur direkten Parametererfassung einer elektrischen Maschine. Es ist ein mathematischer Auswertealgorithmus, der die Maschinenparameter schätzen bzw. verfeinern kann. Er wird in Kombination mit anderen Parametererfassungsmethoden angewendet, da der Algorithmus Eingangsdaten – z. B. die erfassten Daten aus Parametererfassungsmethoden – benötigt. Diese Eingangsgrößen werden durch den Algorithmus verfeinert bzw. abgeleitet, und daraus werden die Maschinenparameter bzw. neue Maschinenparameter bestimmt. Je nach Anwendung ist er optional, da die Standstill-Identification-Verfahren – aus Kapitel 3.4.6 – die endgültigen Parameter auch mittels klassischer Formeln bestimmen können.

Der grundlegende mathematische Ansatz besteht darin, den quadratischen Fehler zwischen gemessenen und modellierten Größen zu minimieren, sodass die geschätzten Parameter iterativ gegen die realen Werte konvergieren (Tang u. a. 2018, S. 5).

Die folgende Formel 10 passt die Parameter nach jedem neuen Messwert an, sodass sie sich schrittweise den tatsächlichen Werten annähern. Mit jedem Schritt werden die Schätzungen genauer.

$$\begin{cases} \hat{\theta}(N+1) = \hat{\theta}(N) + K(N+1)\big(y(N+1) - \varphi^T(N+1)\hat{\theta}(N)\big) \\ K(N+1) = P(N)\varphi(N+1)\big[1 + \varphi^T(N+1)P(N)\varphi(N+1)\big]^{-1} \\ P(N+1) = P(N) - K(N+1)\varphi^T(N+1)P(N) \end{cases} \tag{10}$$

(Tang u. a. 2018, S. 5)

Der Schätzvektor $\hat{\theta}$ wird nach jedem neuen Messwert aktualisiert. Der Gain-Vektor K bestimmt dabei, wie stark der neue Messwert in die Schätzung einfließt. Die Matrix $P(N)$ repräsentiert die Kovarianzmatrix der Schätzung und wird mit jedem Schritt angepasst. Dieser rekursive Prozess ermöglicht es, die geschätzten Parameter den realen Maschinenparametern anzunähern.

Die Methode kann sowohl offline als auch online angewendet werden (Tang u. a. 2018, S. 13–14). In diesem Kapitel wurde sie als Offline-Methode eingeordnet, da sie nach den Offline-Methoden zum Einsatz kommt und nur statisch angewendet wird. Bei der Online-Least-Squares-Methode – aus Kapitel 3.5.2.6 – hingegen werden Parameter dynamisch im laufenden Betrieb optimiert oder abgeleitet (Tang u. a. 2018, S. 6). Sie wird nach Methoden wie der Standstill Identification – Kapitel 3.4.6 – oder dem Rampentest – Kapitel 3.4.5 – verwendet. Parameter wie der Rotorwiderstand R_r, die Hauptinduktivität L_m oder die Streuinduktivität L_σ werden aus Strom-Zeit-Verläufen berechnet. Dabei wird die Differenz zwischen gemessenen und modellierten Größen minimiert. Es handelt sich um eine Optimierung auf Basis eines überbestimmten Gleichungssystems.

Moderne Inverterlösungen aus der Industrie verwenden die Least-Squares-Methode in Kombination mit automatisierten Verfahren. Die Parameter werden nach den automatisierten, nacheinanderfolgenden Verfahren ebenfalls automatisiert durch das Least-Squares-Verfahren optimiert oder hergeleitet.

Da es sich um ein rein numerisches Verfahren handelt, ist der messtechnische Aufwand sehr gering – vorausgesetzt, die Eingangsparameter wurden von anderen Verfahren bestimmt. Die Berechnung ist effizient, jedoch können fehlerhafte Modellannahmen zu Abweichungen führen.

3.4.8 Self-Commissioning

Das Self-Commissioning-Verfahren ist ein vollautomatisiertes Offline-Verfahren zur Erfassung der mechanischen und elektrischen Parameter einer elektrischen Maschine (Schierling 1988, S. 287; Odhano 2014, S. 1; Odhano u. a. 2019, S. 3604). Die Methode wird bei modernen Invertern eingesetzt – sie ist in der Inverter-Software integriert (Kania u. a. 2011, S. 1) – und ist der wichtigste Bestandteil der automatisierten Offline-Parametererfassung in der Industrie. Diese Parameter sind Bestandteil bei der Erstellung eines Maschinenmodells für die Regelung der Maschine durch z. B. FOC oder weitere Regelungsverfahren (Kania u. a. 2011, S. 1). Die Wirksamkeit der Regelung hängt von der Verfügbarkeit präziser Maschinenparameter ab.

In den vorangegangenen Abschnitten wurden einzelne Verfahren zur Offline-Parametererfassung systematisch vorgestellt – darunter der Gleichstromversuch – aus Kapitel 3.4.2 –, der Leerlaufversuch – aus Kapitel 3.4.3 – und der Kurzschlussversuch – aus Kapitel 3.4.4 –. Der Gleichstromversuch und der Kurzschlussversuch bilden zusammen den Standstill-Identification-Prozess – Kapitel 3.4.6 –. Diese Offline-Methoden bilden die Grundlage für das Self-Commissioning-Verfahren.

Die jeweils erfassten Parameter werden innerhalb eines strukturierten Ablaufs nacheinander bestimmt und zur Berechnung weiterer Größen verwendet (Schierling 1988, S. 287–290; Odhano u. a. 2019, S. 3606). Dabei muss der Benutzer nur das Self-Commissioning-Verfahren starten. In wenigen Sekunden oder Minuten – je nach Systemleistung – werden die einzelnen Methoden nacheinander durchgeführt und alle erforderlichen Parameter dem Nutzer bzw. dem Inverter zur Verfügung gestellt bzw. für die Regelung der Maschine bereitgestellt. Der Rampentest/Low-Speed-Test – aus Kapitel 3.4.5 – wird nur bei Bedarf als Teil des Self-Commissioning-Prozesses separat durchgeführt – er ist nicht Teil des vollautomatisierten Verfahrens (Schierling 1988, S. 287). Die folgende Abbildung 9 dient der systematischen Einordnung der jeweiligen Offline-Methoden bezüglich des Self-Commissioning-Prozesses.

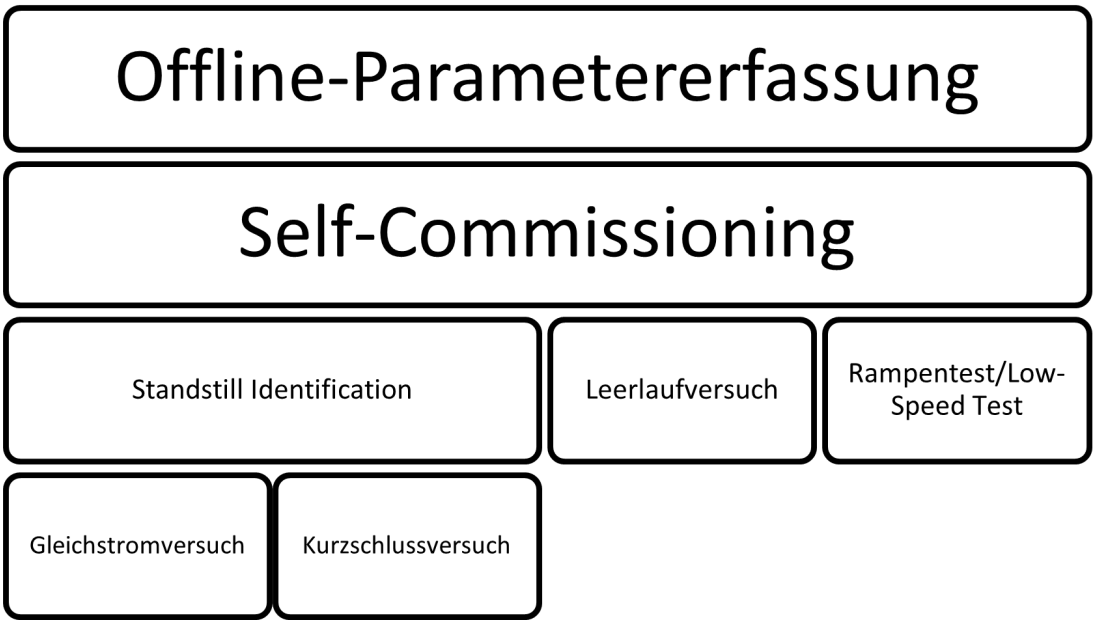

Abbildung 9: Einordnung von Offline-Verfahren im Rahmen des Self-Commissioning-Prozesses moderner Inverter

Beispielsweise muss der Statorwiderstand R_s im Gleichstromversuch bestimmt werden, bevor im Kurzschlussversuch der Rotorwiderstand R_r korrekt erfasst werden kann – da er zur Berechnung der komplexen Eingangsimpedanz benötigt wird. Die Hauptfeldinduktivität L_m – aus dem Leerlaufversuch (Kapitel 3.4.3) – ist ebenso entscheidend für die Ermittlung feldorientierter Stromreferenzen. In der folgenden Abbildung 10 ist der Ablauf des Self-Commissioning-Verfahrens noch einmal mit Hilfe eines Flussdiagramms in Bezug auf die erforderlichen Parameter, die erfassten Parameter und deren Relevanz dargestellt.

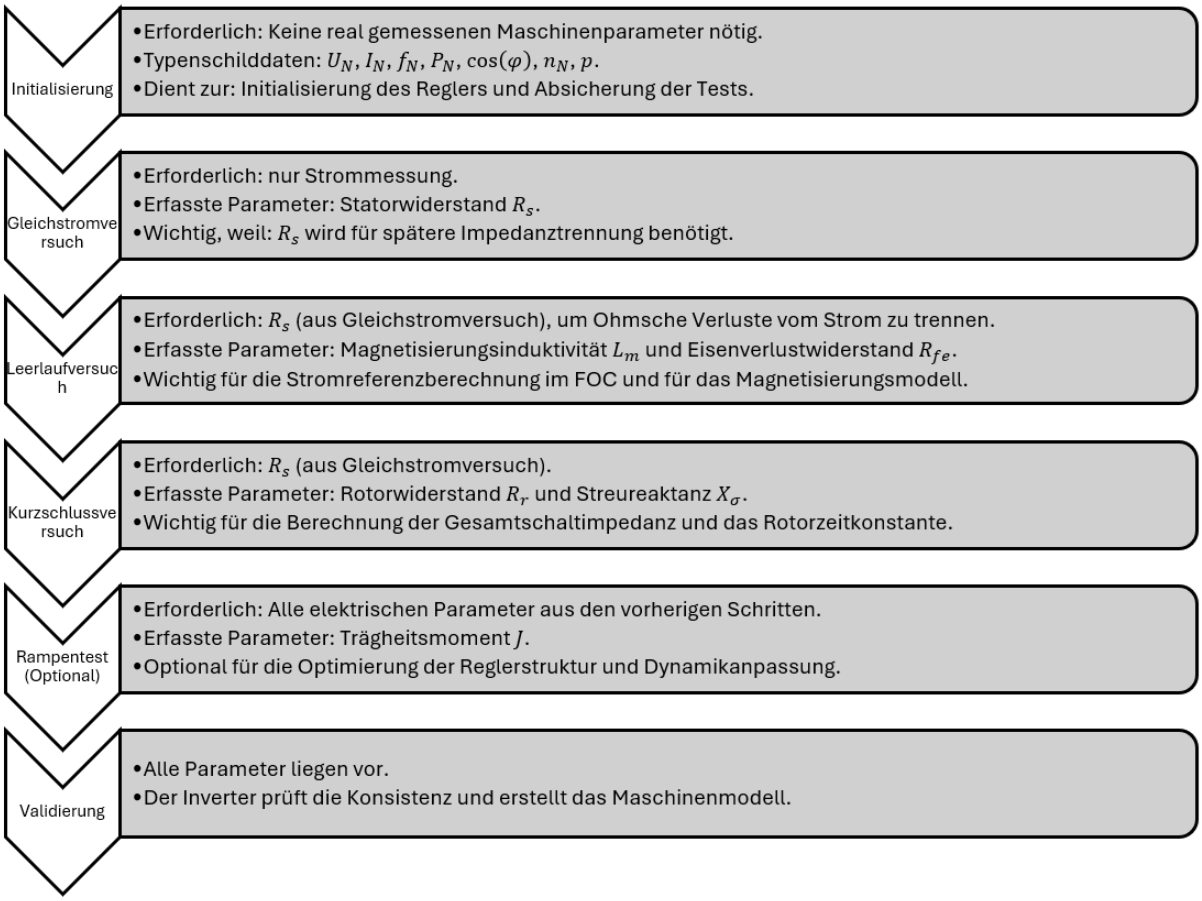

Abbildung 10: Ablauf des Self-Commissioning-Prozesses in modernen Invertern mit zugehörigen Offline-Methoden, benötigten Eingangsdaten und jeweils erfassten Maschinenparametern

Moderne Inverter und Invertersoftware-Hersteller wie Siemens, ABB, Danfoss oder weitere integrieren das Self-Commissioning-Verfahren in ihre Inverter-Software, jedoch unterscheiden sich die Verfahren, je nach Hersteller leicht – folgt in Kapitel 4–. Sie kombinieren die Offline-Methoden mit Auswerteverfahren – wie z. B. Least Squares (Kapitel 3.5.2.6) oder MRAS (Kapitel 3.5.2.3) – zur Schätzung bzw. Näherung der ermittelten Parameter aus den einzelnen automatisiert durchgeführten Verfahren. Dadurch werden noch präzisere Maschinenparameter bestimmt als nur mit einzelnen Offline-Verfahren.

3.4.9 Zusammenfassung der Offline-Methoden

Zusammengefasst lässt sich feststellen, dass die Offline-Parametererfassungsmethoden eine wichtige Rolle für die Erfassung der Maschinenparameter und die korrekte Einstellung der elektrischen Maschine vor der Inbetriebnahme spielen. Dabei unterscheiden sich die einzelnen Methoden voneinander und können einzeln, kombiniert sowie automatisiert durchgeführt werden.

Eine Übersicht zu den Offline-Verfahren ist in Tabelle 3 dargestellt. Dabei ist es möglich, in ruhigen, störungsfreien Umgebungen die typenschildbasierte Abschätzung auszuwählen, wenn

sie die erforderlichen Maschinenparameter deckt. Je nach Betriebszustand oder Anforderung an die Genauigkeit können einzelne Tests wie Gleichstrom-, Leerlauf-, Kurzschlussversuche oder Rampentests durchgeführt werden. Außerdem ist es möglich, ein vollautomatisiertes Verfahren durchzuführen: das Self-Commissioning-Verfahren. Alle erforderlichen Maschinenparameter werden dabei erfasst, indem alle einzelnen Tests nacheinander automatisiert durchgeführt werden. Wichtig ist dabei stets, dass die Kriterien in Tabelle 3 erfüllt werden.

Tabelle 3: Übersicht der Offline-Parametererfassungsverfahren

Verfahren	Erfasste Parameter	Betriebszustand	Genauigkeit	Robustheit	Aufwand
Typenschildbasierte Abschätzung	R_s, R_r, L_m, c_T, J	Kein Betrieb	Niedrig	Sehr gering	Sehr gering
Gleichstromversuch	R_s	Stillstand	Hoch	Gering	Gering
Leerlaufversuch	L_m, R_{Fe}	Leerlauf	Mittel	Mittel	Mittel
Kurzschlussversuch	R_r, X_σ	Stillstand	Mittel–Hoch	Gering	Hoch
Rampentest / Low-Speed-Test	J	Niedrige Drehzahl	Hoch	Mittel	Mittel
Standstill Identification	R_s, R_r, X_σ	Stillstand	Hoch	Mittel	Mittel
Self-Commissioning	Alle Maschinenparameter aus anderen Offline-Methoden	Stillstand + automatische Sequenzen	Hoch	Mittel–Hoch	Gering–Mittel

3.5 Online-Parametererfassung

Die Online-Parametererfassung erfolgt im Gegensatz zur Offline-Parametererfassung – erläutert in Kapitel 3.4 – während des laufenden Betriebs – d. h. die Erfassung erfolgt dynamisch (Tang u. a. 2018, S. 5; Odhano 2014, S. 7; Arnold 2005, S. 35; Richter 2016, S. 52).

Die elektrischen Maschinen stehen dabei unter realen Betriebsbedingungen wie Spannung, Bewegung und wechselnder Belastung. Diese Bedingungen haben Einfluss auf die Temperatur, die magnetische Sättigung und Reibungsverluste, welche wiederum die Parametrierung beeinflussen

(Tang u. a. 2018, S. 5–6; Odhano 2014, S. 7).

Die Online-Parametererfassung kann in zwei unterschiedlichen Wegen durchgeführt werden: entweder durch gezielte Einspeisung von Prüfsignalen in die Wicklungen (Arnold 2005, S. 35) oder durch Beobachtung des Maschinenverhaltens im normalen Betrieb (Arnold 2005, S. 39–40; Bonifacio u. a. 2018, S. 1). Beide Methoden zeichnen das Maschinenverhalten bzw. die Spannungs- und Stromverläufe auf und leiten daraus die relevanten Maschinenparameter ab. Diese Parameter können sowohl elektrische als auch mechanische Größen sein. Je nach Bedarf und Methode können auch gezielt nur die erforderlichen Parameter bestimmt werden (Tang u. a. 2018, S. 2).

Hochdynamische Systeme wie Robotik oder Industrieautomatisierung erfordern Online-Methoden zusätzlich zu den Offline-Methoden zur Parametererfassung, da letztere aufgrund der fehlenden dynamischen Anpassung oft nicht für eine präzise und fehlerfreie Bestimmung ausreichen (Landau u. a. 2011, S. 2–3). Genau für solche Fälle ist die Online-Parametererfassung vorgesehen.

Ein zentraler Vorteil der Online-Methoden besteht darin, dass sie kontinuierlich auf Änderungen im Betriebszustand reagieren können, ohne den Betrieb zu unterbrechen. Aus diesem Grund erfordern sie jedoch auch eine erhöhte Rechenleistung und einen höheren algorithmischen Aufwand (Arnold 2005, S. 35–36; Bonifacio u. a. 2018, S. 1).

In den folgenden Abschnitten werden die wichtigsten Online-Methoden detailliert dargestellt. Insbesondere wird auf die Funktionsprinzipien, Anwendungsmöglichkeiten und die jeweils erfassten Maschinenparameter eingegangen.

3.5.1 Injektionsbasierte Verfahren

Injektionsbasierte Verfahren sind die wichtigsten, einfachsten und am weitesten verbreiteten Online-Methoden zur Parametererfassung elektrischer Maschinen durch Inverter. Sie erzeugen künstliche Spannungs- oder Stromsignale. Diese Signale werden in die Wicklungen der elektrischen Maschine eingespeist, während die Maschine sich im Betrieb befindet. Die Maschine reagiert auf diese Signale mit einer messbaren Strom- oder Sprungantwort (Tang u. a. 2018, S. 8–9; Bonifacio u. a. 2018, S. 1). Dieses Signal wird durch den Inverter erfasst und weiterverwendet, um die erforderlichen Maschinenparameter daraus zu erfassen bzw. abzuleiten.

Diese Verfahren eignen sich besonders zur Identifikation von Parametern, die im Stillstand nicht erfasst werden können oder bei dynamischer Last ihre Bedeutung haben, wie z. B. temperaturabhängige Widerstände (Tang u. a. 2018, S. 2, 8), Rotorfluss ψ_r (Liu et al. 2023, S. 5791), Leckinduktivitäten L_σ oder die Magnetisierungsinduktivität L_m (Tang u. a. 2018, S. 2). Injektionsmethoden werden auch bei sensorlosen Regelungen eingesetzt, um z. B. die Rotorlage Θ_r zu ermitteln (Bui u. a. 2020, S. 1009).

Der größte Vorteil von Signalinjektion ist die Eignung für den laufenden Betrieb. Sie können auch zusätzlich zu Offline-Methoden eingesetzt werden, um die Ergebnisse bzw. Parameter aus diesen Verfahren zu verfeinern – in Echtzeit. Typische Injektionsverfahren unterscheiden sich in:

- der Art des eingespeisten Signals, z. B. Gleichsignal – DC-Injektion –, hochfrequente Signale – HF-Injektion – (Tang u. a. 2018, S. 8–10), rotierende Spannungsvektoren oder pulsartige Spannungen (S. Liu u. a. 2023, S. 5791).
- dem Frequenzbereich der Einspeisung (Tang u. a. 2018, S. 10).
- sowie dem Zielparameter, der jeweils identifiziert werden soll.

In den folgenden Abschnitten sind die wichtigsten Injektionsmethoden zu finden, und die typischen Zielgrößen, die im Rahmen der automatisierten Parametrierung durch moderne Inverter erfasst werden, werden analysiert. Tabelle 4 schafft dabei eine Übersicht über alle in den folgenden Abschnitten behandelten Injektionsverfahren und zeigt die jeweils erfassten Parameter, die Art des eingespeisten Signals, den erforderlichen Maschinenzustand sowie typische Einsatzbereiche.

Tabelle 4: Übersicht über injektionsbasierte Online-Methoden

Verfahren	**Erfasste Parameter**	**Einspeisesignal**	**Zustand der Maschine**	**Typischer Einsatz**
DC-Injektion	R_s	Konstante Gleichspannung	Sehr langsame Drehung	Initiale Widerstandsmessung, Temperaturüberwachung
HF-Injektion	L_σ, Θ_r	Hochfrequente sinusförmige Spannung	Niedrige Drehzahl	Rotorlageerkennung bei sensorloser FOC
Rotating Voltage Injection	Θ_r	Rotierender Spannungsvektor (d–q)	Niedrige Drehzahl	Sensorlose Initialisierung, Rotorlagenachführung
Pulsinjektion	Θ_r	Kurzzeitiger Spannungspuls	Beliebig / laufender Betrieb	Laufzeitkorrektur, Diagnose, adaptive Modellanpassung

3.5.1.1 DC Signal Injection

Die DC-Signal-Injektion ist die einfachste Injektionsmethode. Ein Gleichstromsignal oder eine konstante Gleichspannung wird in die Ständerwicklung eingespeist (Tang u. a. 2018, S. 8). Die Maschine wird mit sehr niedriger Drehzahl betrieben. Die Maschine reagiert auf die eingespeisten Signale durch einen erzeugten Gleichstromfluss. Dieser Gleichstromfluss wird vom Inverter erfasst. Durch das Ohm'sche Gesetz lassen sich einfache elektrische Parameter, wie z. B. der Statorwiderstand R_s (S. Li u. a. 2024, S. 267; Tang u. a. 2018, S. 16), direkt mit der Formel 11 bestimmen:

$$R_s = \frac{U_{DC}}{I_{DC}} \tag{11}$$

(Tang u. a. 2018, S. 8)

Dabei ist U_{DC} die angelegte Gleichspannung und I_{DC} der resultierende Gleichstrom. Die DC-Injektion ist besonders nützlich für die laufende Anpassung von R_S, da dieser temperaturabhängig ist, sowie für die initiale Widerstandsmessung im Self-Commissioning-Prozess (Kania u. a. 2011, S. 3).

Moderne Inverter führen dieses Verfahren während des Betriebs in bestimmten Abständen automatisch durch, da sich auch die Temperatur und andere dynamische Bedingungen während des Betriebs ändern können.

Abbildung 11 zeigt das Blockschaltbild zur Identifikation des Statorwiderstands, bei dem ein konstanter Strom in die d-Achse eingespeist wird. Abbildung 12 veranschaulicht die FOC-Regelstruktur mit einer DC-Offseteinspeisung, die zur Online-Identifikation von Maschinenparametern genutzt wird.

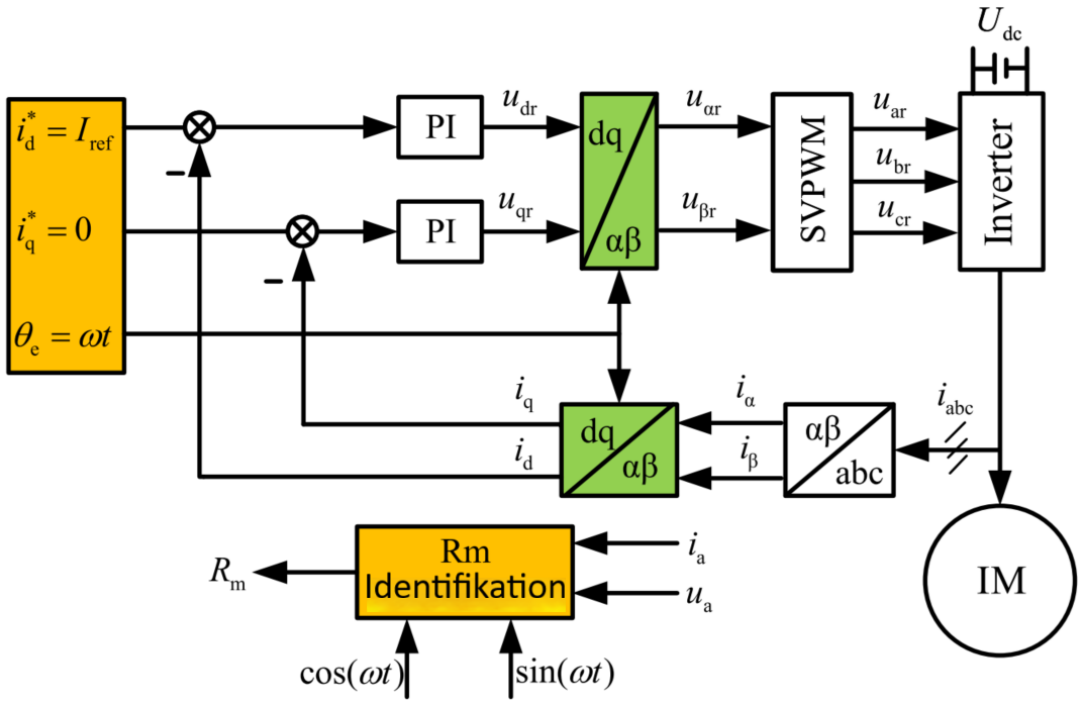

Abbildung 11: Identifikation von Statorwiderstand durch DC-Injektion in die d-Achse (S. Li u. a. 2024, S. 268)

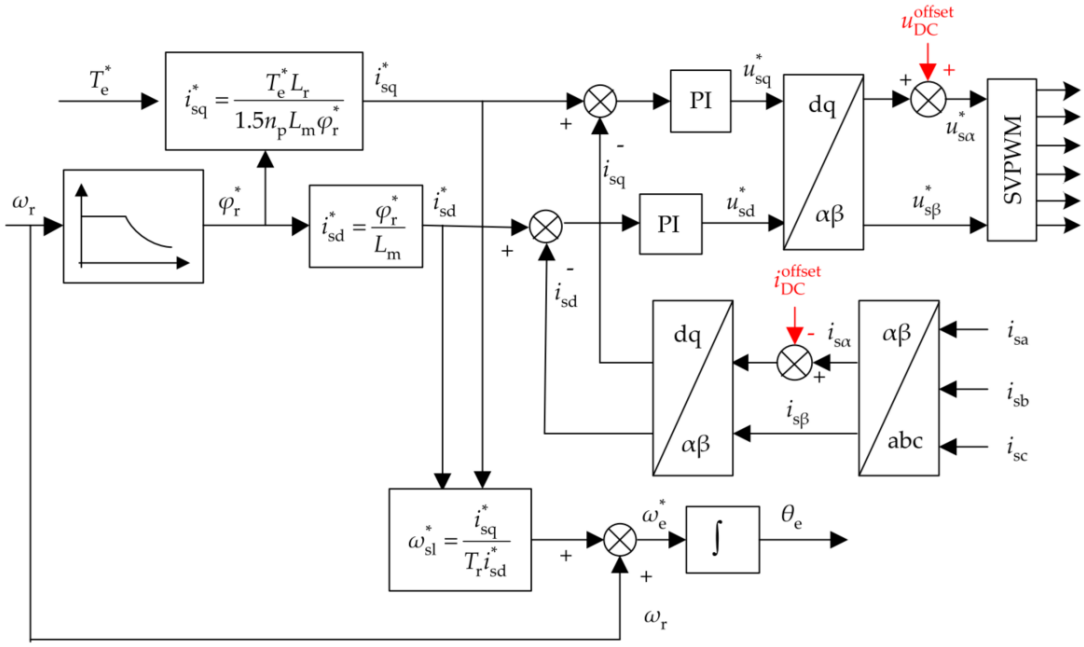

Abbildung 12: FOC-Regelstruktur mit DC-Offseteinspeisung zur Online-Identifikation von Maschinenparametern (Tang u. a. 2018, S. 8)

Die DC-Injektion ist sehr einfach umsetzbar, da keine Frequenzanalyse oder komplexe Filterung notwendig ist. Sie erfasst jedoch nur einen Parameter. Aus diesem Grund ist sie oft allein nicht brauchbar bzw. muss mit anderen Methoden kombiniert angewendet werden, um eine lückenlose Parametrierung zu ermöglichen.

3.5.1.2 HF Signal Injection

Bei der HF-Signal-Injektion handelt es sich um eine erweiterte Injektionsmethode. Hochfrequente Wechselspannungen werden gezielt in die Ständerwicklung eingespeist (Tang u. a. 2018, S. 10; Q. Z. Zhu und Wu 2024, S. 105–108). Die Leckinduktivität L_σ, der Rotorwiderstand R_r (Tang u. a. 2018, S. 10) und die Rotorlage θ_r (Q. Z. Zhu und Wu 2024, S. 108; Chen 2015, S. 8) werden durch diese Methode bestimmt.

Die Maschine läuft – wie bei der DC-Injektion aus Kapitel 3.5.1.1 – mit sehr niedriger Drehzahl (Q. Z. Zhu und Wu 2024, S. 93–103). Im Gegensatz zur DC-Injektion wird hier bei hohen Frequenzen gemessen. Induktive Eigenschaften einer elektrischen Maschine wirken in hohen Frequenzbereichen stark (Fischer und Nolle 2022, S. 27; Babiel 2023, S. 47), was die Bestimmung weiterer Parameter ermöglicht. Abbildung 13 zeigt eine vereinfachte Darstellung der HF-Signal-Injektion. $\Delta u_{s,hf}$ bezeichnet die hochfrequente Wechselspannung, und $\Delta i_{s,hf}$ den dazugehörigen Strom.

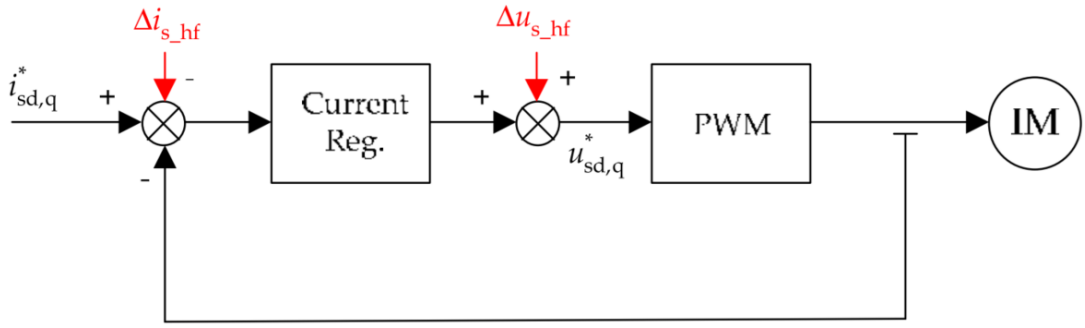

Abbildung 13: Vereinfachtes Schema der Hochfrequenz-Wechselspannungseinspeisung zur Online-Parameteridentifikation (Tang u. a. 2018, S. 10)

Ein sinusförmiges HF-Signal wird eingespeist, und die Stromantwort wird vom Inverter erfasst und ausgewertet. Durch die Anregung in einem hohen Frequenzbereich kann die Maschine auf magnetisch unsymmetrische Eigenschaften geprüft werden. Die Frequenz liegt oft zwischen einigen hundert Hertz bis in den Kilohertzbereich (Schröder 2012, S. 1563–1564). .

Die Rotorlage ist nützlich für die sensorlose Regelung. Die HF-Signal-Injektion erfordert eine gute Filterung und eine genaue Modellierung der Reaktion, da HF-Signale empfindlich gegenüber Rauschen sind und die HF-Signale von anderen Signalen unterschieden werden müssen (Tang u. a. 2018, S. 10; Q. Z. Zhu und Wu 2024, S. 102). Diese Methode ist besonders nützlich für Maschinen oder Zustände, in denen Parameter dynamisch, aber ohne Bewegung ermittelt werden müssen.

Moderne Inverter-Systeme führen die HF-Injektion als Bestandteil der sensorlosen Anlaufregelung oder der Online-Feinjustierung automatisch durch.

3.5.1.3 Rotating Voltage Injection

Bei der Rotating-Voltage-Injektion wird ein rotierender Spannungsvektor künstlich durch einen Inverter erzeugt. Dieser Vektor wird ins Statorfeld eingespeist, und die Maschine wird dadurch durch eine Spannungsanregung beaufschlagt. Dabei bewegt sich die Maschine mit sehr niedriger Drehzahl (Q. Z. Zhu und Wu 2024, S. 158–161, 189–193).

Durch die gezielte Rotation des Spannungsvektors wird eine definierte Reaktion im d-q-Koordinatensystem erzeugt (S. Li u. a. 2024, S. 267).

Die folgende Formel 12 zeigt die mathematische Darstellung eines rotierenden Spannungsvektors $u_{dq}(t)$ im d-q-Koordinatensystem. Die Formel soll zur Orientierung dienen. Dieses System beschreibt die Spannungen entlang zweier Achsen, die mit dem Rotor mitrotieren – der sogenannten d-Achse – direkt – und der q-Achse – quadratur –. Der Vektor besteht aus zwei sinusförmigen Komponenten. Diese Komponenten stehen orthogonal zueinander und stellen gemeinsam eine konstante Amplitude dar. Der Vektor wird für die Rotorlagenbestimmung verwendet.

$$u_{dq(t)} = \hat{U} \cdot \begin{bmatrix} \cos(\omega t) \\ \sin(\omega t) \end{bmatrix} \tag{12}$$

(Lu u. a. 2022, S. 3; Q. Z. Zhu und Wu 2024, S. 105)

Durch die rotierende Spannung lässt sich die Lage des Rotors Θ_r (Jansen und Lorenz 1995, S. 242; Toudert 2023, S. 193; Chen 2015, S. 8; Q. Z. Zhu und Wu 2024, S. 105–110) ohne Positionssensor sehr genau bestimmen – auch im Stillstand. Trotz der hohen Genauigkeit bei der Rotorlagebestimmung ist die Methode sehr rechenaufwendig, da die Signale im d-q-Raum analysiert und interpretiert werden müssen.

Moderne Inverter nutzen die *Rotating-Voltage-Injektion* als ergänzendes Verfahren zur Rotorlagebestimmung im niedrigen Drehzahlbereich.

3.5.1.4 Pulsinjektion

Bei der Pulsinjektion werden kurzzeitige Spannungspulse in die Wicklungen der Maschine eingespeist (Toudert 2023, S. 188; Wang u. a. 2021, S. 186–189). Die Pulse können entweder in einer oder mehreren Phasen nacheinander erfolgen oder gezielt entlang bestimmter Achsen im d-q-Koordinatensystem.

Der Inverter misst die Stromantwort nach dem Einspeisen eines Spannungspulses. Aus dem zeitlichen Verlauf des Stromanstiegs werden elektrische Parameter der Maschine bestimmt (Q. Z. Zhu und Wu 2024, S. 100–103). Im Gegensatz zu anderen Injektionsmethoden sind keine kontinuierlichen Signalformen benötigt, sondern plötzliche Spannungssprünge. Die Pulsinjektion

dient hauptsächlich zur Erfassung der Rotorlage θ_r (Toudert 2023, S. 188; Q. Z. Zhu und Wu 2024, S. 100–102, 232–234).

Die Pulsinjektion schickt nur ganz kurze Pulse; aus diesem Grund stört sie den Maschinenbetrieb nur minimal (Wang u. a. 2021, S. 189). Auch die Rechenlast ist aus diesem Grund sehr gering. Die Methode kann im laufenden Betrieb zur periodischen Überprüfung oder Aktualisierung bestimmter Modellparameter im Hintergrund eingesetzt werden. Ein Filter ist bei der Pulsinjektion notwendig, da die Stromantwort gegen Störungen und Rauschen empfindlich ist (Q. Z. Zhu und Wu 2024, S. 100–102).

Die Methode liefert sehr gute Ergebnisse, wenn saubere Stromverläufe verfügbar sind. Moderne Inverter nutzen die Pulsinjektion als Teil spezieller Diagnose- oder Nachregelprozesse, besonders zur adaptiven Modellanpassung.

3.5.2 Observer-gestützte Methoden

Die Observer-gestützten Methoden gehören zu den modellbasierten Online-Verfahren der Parametererfassung elektrischer Maschinen. D. h., wo die Messungen und Algorithmen nicht ausreichen – wo Sensorik fehlt oder ersetzt werden soll – bzw. nicht die erforderlichen Parameter erfassen können, werden mathematische Modelle aufgebaut (Tang u. a. 2018, S. 10–11; Chen 2015, S. 20–21) um dynamische Parameter wie den Rotorfluss Ψ_r (Kaźmierkowski u. a. 2002, S. 314), die Rotorlage Θ_r (Chen 2015, S. 21; Q. Z. Zhu und Wu 2024, S. 412–413) oder die Rotorzeitkonstante T_r (Kaźmierkowski u. a. 2002, S. 184) zu bestimmen. Dabei werden die gemessenen Größen wie Strom (Chen 2015, S. 21) und Spannung als Eingangsgrößen verwendet (Chen 2015, S. 20).

Ein Beobachter vergleicht während des Betriebs kontinuierlich die gemessenen Größen mit den Modellausgaben. Daraus schätzt er sowohl die statischen als auch die dynamischen Parameter der elektrischen Maschine. Es gibt zwei Arten von Modellen: lineare und nichtlineare, je nach Verfahren und Maschinenkomplexität. Somit erfolgt die kontinuierliche Laufzeitabschätzung wichtiger Maschinenparameter.

Die typischen Parameter, die mit Observern geschätzt bzw. bestimmt werden, sind: der Rotorfluss ψ_r (Kaźmierkowski u. a. 2002, S. 314), die Rotorlage Θ_r (Chen 2015, S. 21; Q. Z. Zhu und Wu 2024, S. 412), die mechanische Drehzahl ω_r (Chen 2015, S. 21; Q. Z. Zhu und Wu 2024, S. 412), die Rotorzeitkonstante T_r (Kaźmierkowski u. a. 2002, S. 184) und der Rotorwiderstand R_r (Arnold 2005, S. 40). Der Rotorwiderstand R_s und die Rotorzeitkonstante T_r werden jedoch selten durch Observer bestimmt, im Vergleich zu der Rotorlage Θ_r und der mechanischen Drehzahl ω_r. Diese beiden Parameter werden aus dem Rotorfluss ψ_r hergeleitet.

Tabelle 5 dient als Übersicht zu den Observer-gestützten Methoden.

Tabelle 5: Übersicht modell- und schätzbasierter Verfahren zur Online-Parametererfassung hinsichtlich Modelltyp, Einsatzbereich und typischer Zielgrößen

Verfahren	**Erfasste Parameter**	**Modelltyp**	**Zustand der Maschine**
Luenberger-Observer	θ_r, ω_r	Linear	Mittlere bis hohe Drehzahl
Sliding-Mode-Observer	θ_r, ω_r	Nichtlinear	Mittlere bis hohe Drehzahl
MRAS	θ_r, ω_r	Nichtlinear / Adaptiv	Mittlere bis hohe Drehzahl
Extended Kalman Filter	θ_r, ω_r	Nichtlinear / Stochastisch	Gesamter Bereich
Direct Flux & Torque Estimation	Ψ_s, T_e	Modellfrei (direkt)	Mittlere Drehzahl
Recursive Least Squares	Feinjustierung der Verfahren aus dem Self-Commissioning-Verfahren	Modellgestützt (regressiv)	Mittlere bis hohe Drehzahl

Die Observer-gestützten Methoden sind sehr flexibel anzuwenden. D. h., sie können mit anderen Methoden kombiniert werden – zur Abschätzung der Parameter oder zum Vergleich und Abgleich der Parameter, die aus anderen Methoden bestimmt wurden. Dynamische Veränderungen im System, wie Temperaturänderungen, sind aufgrund der kontinuierlichen Messung kein Problem.

Ein Beispiel zur Rotorlagen- und Zustandsbestimmung aus der Praxis wäre die Kombination aus Injektionsverfahren – aus Kapitel 3.5.1 – und Observer-gestützten Methoden (Q. Z. Zhu und Wu 2024, S. 107–108): Während Injektionsverfahren gezielt lageabhängige Reaktionen auslösen, können Observer diese Informationen dynamisch weiterverarbeiten und zur Echtzeitüberwachung einsetzen. Die Kombination erlaubt eine robuste und lückenlose Rotorlagen- und Zustandsbestimmung im gesamten Drehzahlbereich.

Abbildung 14 zeigt ein kombiniertes Verfahren, bei dem Signalinjektion und Beobachter kombiniert werden, um daraus die Rotorlage und die Drehzahl zu bestimmen.

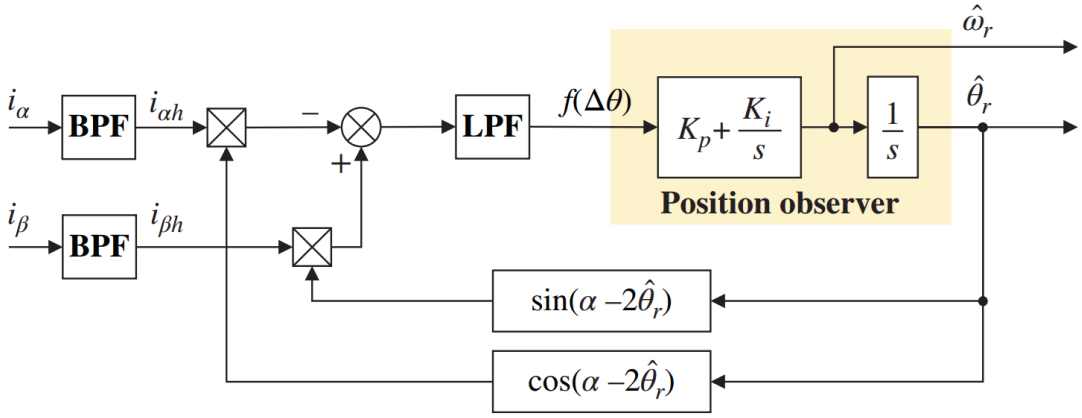

Abbildung 14: Kombination aus hochfrequenter Signalinjektion und Positionsbeobachter zur Bestimmung von Rotorlage und Drehzahl (Q. Z. Zhu und Wu 2024, S. 107)

Moderne Inverter nutzen Beobachter häufig als integrierte Algorithmen zur Feinjustierung der Parameter.

Die nachfolgenden Abschnitte stellen die wichtigsten Observer-gestützten Methoden vor. Zu beachten dabei ist, dass in dieser Arbeit auch MRAS und EKF als Observer behandelt werden.

3.5.2.1 Luenberger Observer

Der Luenberger-Beobachter – engl. Luenberger Observer – ist die klassische Form eines linearen Zustandsbeobachters (Luenberger 1971, S. 596–601). Ein mathematisches Modell der elektrischen Maschine wird in Zustandsraumdarstellung erstellt. Dieses Modell bestimmt durch die Differenz zwischen den gemessenen und modellierten Größen nicht direkt messbare Größen – kontinuierlich (Tang u. a. 2018, S. 10–11; Luenberger 1971, S. 597–599).

Im Prinzip werden durch das virtuelle Maschinenmodell die erwarteten Ausgangswerte wie Strom und Spannung berechnet. Diese werden mit den real gemessenen Werten verglichen. Aus der Differenz werden die Parameter geschätzt bzw. kontinuierlich angepasst (Schröder und Böcker 2021, S. 151).

Die allgemeine Struktur wird in den Formeln 13, 14, 15 und 16 gezeigt:

$$\dot{\hat{x}} = A\hat{x} + bu + k\Delta y \tag{13}$$

$$\Delta y = y - \hat{y} = c^T x - c^T \hat{x} \tag{14}$$

$$\begin{cases} \dot{\hat{x}}(t) = A\hat{x}(t) + L\big(y(t) - \hat{y}(t)\big) + Bu(t) \\ y(t) = C\hat{x}(t) \end{cases} \tag{15}$$

$$\tilde{x} = A\hat{x} + Bu + L\big(y - \hat{y}\big) \tag{16}$$

(Luenberger 1971, S. 596–601) (Tang u. a. 2018, S. 10–11; Schröder und Böcker 2021, S. 150–152)

Dabei bezeichnet $\hat{x}$ den geschätzten Zustandsvektor, also die intern berechneten Maschinenzustände. Die Matrizen A und B beschreiben das Maschinenmodell im Zustandsraum, während u die Eingangssignale darstellt. Die Messgröße y wird mit dem modellierten Ausgang $\hat{y}$ verglichen, und die Differenz $y - \hat{y}$ wird über die Beobachtungsmatrix L als Korrektur auf die Systemdynamik rückgeführt.

Abbildung 15 zeigt den Aufbau eines Luenberger-Beobachters. Oben ist das reale System mit dem Zustandsvektor x und dem Ausgang y dargestellt, unten der Beobachter mit dem geschätzten Zustandsvektor $\hat{x}$ und dem geschätzten Ausgang $\hat{y}$. Die Differenz $\Delta y = y - \hat{y}$ wird über die Beobachtungsmatrix L – Fehlerrückkopplung – in die Dynamik des Beobachters eingespeist. Dadurch wird $\hat{x}$ kontinuierlich angepasst, sodass es sich dem tatsächlichen Zustand x annähert.

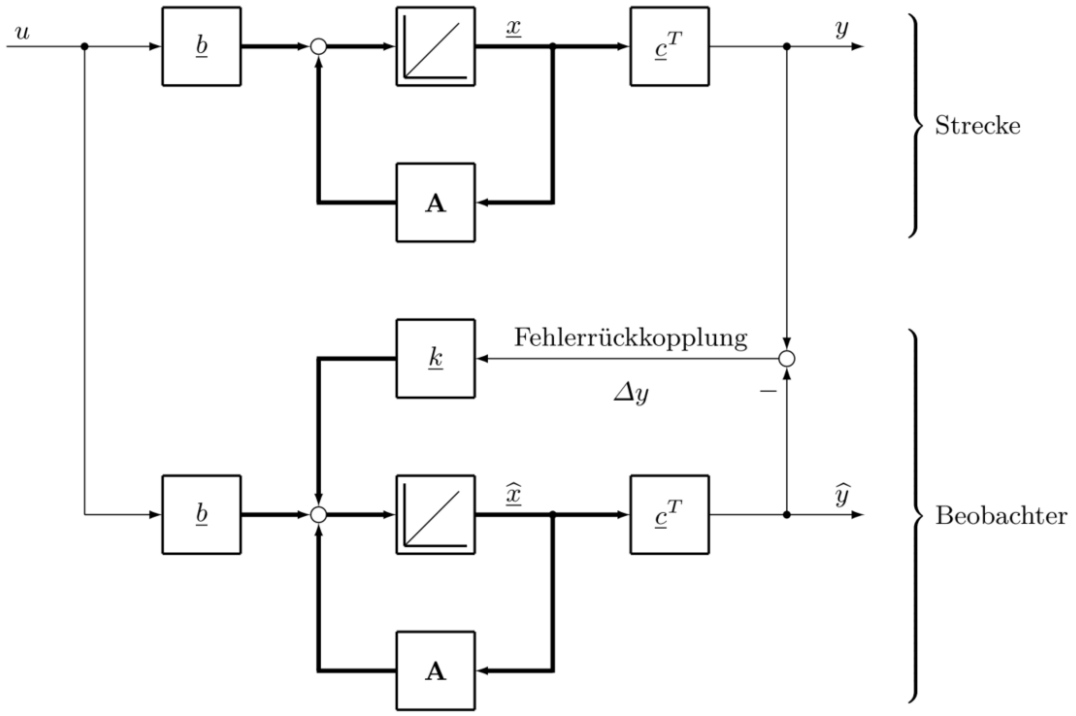

Abbildung 15: Luenberger-Beobachter (Schröder und Böcker 2021, S. 150)

Der Luenberger-Beobachter wird zur Bestimmung der Rotorlage θ_r und der mechanischen Drehzahl ω_r verwendet (Kaźmierkowski u. a. 2002, S. 314, 329; Jansen und Lorenz 1995, S. 242).

Da diese Größen auf dem geschätzten Rotorfluss ψ_r basieren, muss dieser zunächst im Modell berücksichtigt werden. Somit erfolgt die Ermittlung der Rotorlage θ_r und der mechanischen Drehzahl ω_r indirekt über die vorherige Bestimmung des Rotorflusses ψ_r (Kang Hyo Park u. a. 2011, S. 2968).

Der Luenberger-Beobachter ist rechentechnisch effizient und einfach zu implementieren. Es ist jedoch zu beachten, dass die Qualität eines Luenberger-Beobachters stark von der Modellgüte und den Systemparametern abhängt. Störungen oder Modellabweichungen können je nach Stärke einen großen Einfluss auf die Schätzung haben, weshalb die Methode auch mit anderen Methoden kombiniert wird.

3.5.2.2 Sliding Mode Observer

Der Sliding-Mode-Observer ist ein nichtlinearer Zustandsbeobachter (Q. Z. Zhu und Wu 2024, S. 413). Er eignet sich besonders für Systeme mit Modellabweichungen oder Störungen, im Gegensatz zum Luenberger-Beobachter – Kapitel 3.5.2.1 oder dem Kalman-Filter – Kapitel 3.5.2.4 – (Y. Liu u. a. 2020, S. 2; Q. Z. Zhu und Wu 2024, S. 413). Das Verfahren basiert auf dem Konzept der Gleitmodusregelung – Sliding Mode Control –. Systemzustände werden auf eine Gleitfläche gezwungen, und das Verhalten des Systems wird von bestimmten Modellfehlern befreit bzw. unabhängig (Q. Z. Zhu und Wu 2024, S. 413–414).

Die Rotorlage θ_r und die mechanische Drehzahl ω_r (Q. Z. Zhu und Wu 2024, S. 413–415) werden – wie bei den anderen Methoden auch – aus einem gebildeten Maschinenmodell abgeleitet. Dabei sind die gemessenen Eingangssignale sowie die Ausgangsgrößen von großer Bedeutung. Das System wird gegen Unsicherheiten stabilisiert, indem ein Korrekturterm eine Vorzeichenfunktion enthält – durch die Signum-Funktion (Y. Liu u. a. 2020, S. 5–6), die in Formel 17 zu sehen ist. Das Fehlerverhalten wird gezielt geschaltet.

Die typische Struktur eines Sliding-Mode-Observers lässt sich wie folgt beschreiben:

$$\dot{\hat{x}} = A\hat{x} + Bu + G \cdot \operatorname{sgn}(e) \tag{17}$$

(Y. Liu u. a. 2020, S. 4–5; Q. Z. Zhu und Wu 2024, S. 414)

Dabei bezeichnet $\hat{x}$ den geschätzten Zustandsvektor. $A\hat{x} + Bu$ beschreibt das Maschinenmodell im Zustandsraum, und $e = y - \hat{y}$ ist der Fehler zwischen gemessener und modellierter Ausgangsgröße. Die Funktion $\operatorname{sgn}(e)$ ist eine Vorzeichenfunktion, die den Korrekturterm je nach Fehlerrichtung positiv oder negativ schaltet – siehe Formel 18 –. G ist dabei der Verstärkungsfaktor und bestimmt die Stärke der Rückführung.

$$\operatorname{sgn}(x) = \begin{cases} 1, & \text{wenn } x > 0 \\ -1, & \text{wenn } x < 0 \end{cases} \tag{18}$$

(Tang u. a. 2018, S. 11)

Die Methode eignet sich besonders gut für stark gestörte Anwendungen, oder für Systeme, bei denen die Maschinenparameter ungenau bekannt sind. In modernen Invertern bietet der Sliding-Mode-Observer eine robuste Alternative zu klassischen Methoden bei mittleren bis hohen Drehzahl. Dabei benötigt er jedoch eine Filterung, um hochfrequente Schwingungen in der Ausgangsgröße zu vermeiden (Q. Z. Zhu und Wu 2024, S. 413–415).

3.5.2.3 Model Reference Adaptive System (MRAS)

Das Model Reference Adaptive System ist ein adaptiver – das heißt, seine Linearität hängt von der jeweiligen Anwendung ab – Beobachter (Ta u. a. 2001, S. 1417; Tang u. a. 2018, S. 7). Zwei parallele Modelle werden dabei zur Schätzung verwendet – ein Referenzmodell und ein anpassbares – adaptives – Modell (Tang u. a. 2018, S. 7). Dabei werden die Rotorlage Θ_r und Drehzahl ω_r (Chen 2015, S. 21; Ta u. a. 2001, S. 1417; Q. Z. Zhu und Wu 2024, S. 406–409) bestimmt.

Beide Modelle berechnen dieselbe physikalische Größe auf unterschiedliche Weise. Das Referenzmodell basiert auf gemessenen Größen – Strom und Spannung –, wie beim Luenberger-Beobachter aus Kapitel 3.5.2.1 oder beim Sliding-Mode-Observer aus Kapitel 3.5.2.2, während das adaptive Modell interne Maschinenparameter wie den Rotorwiderstand R_r oder die Drehzahl ω_r verwendet (Tang u. a. 2018). Der Fehler zwischen den beiden Modellen wird dafür verwendet, die unbekannten Parameter im adaptiven Modell schrittweise so anzupassen, dass seine Ausgabe mit dem Referenzmodell übereinstimmt (Ta u. a. 2001, S. 1417–1420; Q. Z. Zhu und Wu 2024, S. 406). Abbildung 16 zeigt das Grundprinzip des MRAS-Verfahrens. Ein Referenzmodell und ein anpassbares Modell erhalten denselben Eingang. Der Unterschied ihrer Ausgaben wird als Fehlergröße e bezeichnet. Der Mechanismus passt die Parameter so lange an, bis die Ausgabe des anpassbaren Modells mit der des Referenzmodells übereinstimmt.

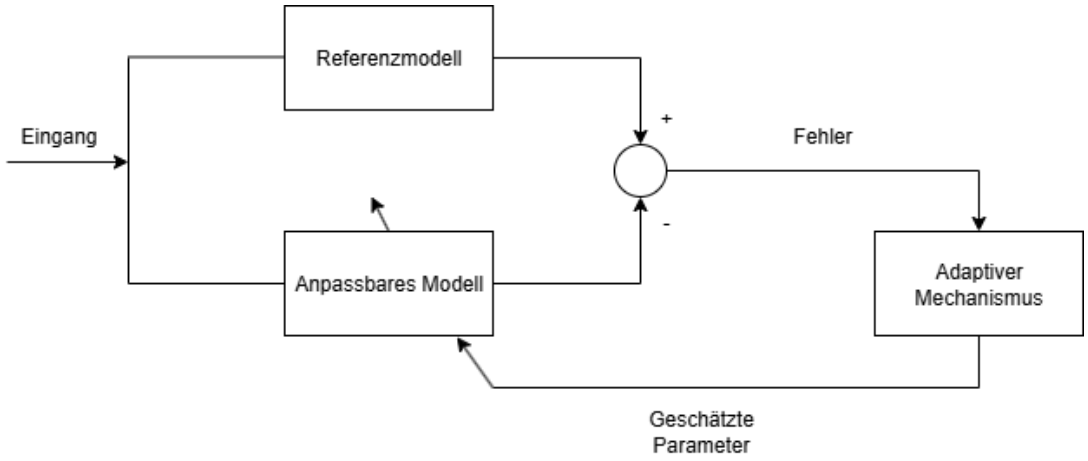

Abbildung 16: Prinzip des modellreferenzierten adaptiven Systems (MRAS) zur Online-Parameteridentifikation (Tang u. a. 2018, S. 7)

Dabei ist x der Ausgang des Referenzmodells, y_{adj} der Ausgang des adaptiven Modells und e_t der Fehler zwischen beiden. Die Funktion $f(e)$ ist ein Regler – z. B. PI-Regler –. Er steuert die Anpassung der zu schätzenden Größe θ – z. B. Drehzahl –.

MRAS wird in der elektrischen Maschinenregelung neben der Parameterbestimmung anschließend für die Maschinenregelung angewendet. Es weist eine hohe Genauigkeit und Echtzeitfähigkeit auf. Wie bei den anderen Beobachtern ist sie bei schlechten Modellparametern unpräzise, kann mehrere Parameter gleichzeitig, gar nicht oder nur schlecht bestimmen und sollte mit anderen Verfahren kombiniert werden, um eine hohe Stabilität zu gewährleisten (Tang u. a. 2018, S. 7).

Moderne Inverter nutzen MRAS besonders für sensorlose Drehzahl- und Lagebestimmung. MRAS eignet sich besonders gut für mittlere bis hohe Drehzahlen.

3.5.2.4 Extended Kalman Filter

Der Extended Kalman Filter ist ein nichtlinearer, stochastischer Beobachter (L. Et-Taaj u. a. 2019, S. 1; X. Li und Kennel 2021, S. 2858; Schröder und Böcker 2021, S. 153; Q. Z. Zhu und Wu 2024, S. 418). Obwohl er sehr komplex ist, wird er in der Antriebstechnik sehr oft verwendet, da er sowohl Zustände als auch Parameter sehr präzise bestimmen kann (Chen 2015, S. 21).

Der zentrale Zweck dieser Methode ist die Zustandsschätzung unter Berücksichtigung von Messrauschen und Modellunsicherheiten. Das nichtlineare System wird mithilfe einer linearen Approximation – z. B. durch Taylor-Entwicklung – lokal linearisiert (Tang u. a. 2018, S. 11; L. Et-Taaj u. a. 2019, S. 3). Dadurch wird es ermöglicht, Zustände wie die Rotorlage Θ_r, die Drehzahl ω_r (Chen 2015, S. 21) und den Rotorwiderstand R_r sowie Statorwiderstand R_s (Tang u. a. 2018, S. 11) zuverlässig zu schätzen.

Im Unterschied zu den anderen Beobachtern wie dem Luenberger-Beobachter – aus Kapitel

3.5.2.1 – oder dem MRAS – aus Kapitel 3.5.2.3 – verwendet der EKF kovarianzbasierte Gewichtungen. Die Unsicherheiten von Modell und Messung können durch diese Gewichtungen mathematisch erfasst werden (L. Et-Taaj u. a. 2019, S. 3), was den EKF geeignet macht für sehr komplexe Systeme mit hohen Modellwissen, Messdaten und Statistik werden kombiniert, um die bestmögliche Schätzung zu liefern. Die Rückkopplung wird dabei direkt aus diesen Kovarianzen abgeleitet, was bei klassischen Beobachtern nicht der Fall ist (Schröder und Böcker 2021, S. 153).

Der EKF besteht aus zwei Schritten: (X. Li und Kennel 2021, S. 2858; L. Et-Taaj u. a. 2019, S. 4; Q. Z. Zhu und Wu 2024, S. 419–420)

- Prädiktion: Das Systemmodell wird vorwärts integriert, um die erwarteten Zustände vorherzusagen.
- Korrektur: Die Vorhersage wird mit der Messung verglichen, und basierend auf der Kovarianz des Fehlers wird die Schätzung angepasst.

Insgesamt lässt sich sagen, dass der EKF eine hohe Genauigkeit bei unsicheren Daten liefert. Von daher ist er besonders geeignet für sensorlose Regelung bei schwierigen Betriebsbedingungen. Gleichzeitig ist die Methode sehr rechenintensiv und erfordert hochleistungsfähige Inverterhardware für die Echtzeitanwendung. Der EKF wird in modernen Invertern häufig eingesetzt; mehrere Maschinenparameter können dadurch gleichzeitig, aber rechenintensiv, abgeschätzt werden.

3.5.2.5 Direct Flux and Torque Estimation

Die Direct Flux and Torque Estimation (DFTE) ist eine modellfreie Methode. Zentrale Maschinenzustände wie Ständerfluss ψ_s und Drehmoment T_e werden direkt aus den gemessenen Spannungs- und Stromgrößen berechnet. Dabei gibt es keine expliziten mathematischen Maschinenmodelle oder Beobachter (Sadek u. a. 2022, S. 2324; Sadek u. a. 2022, S. 2327; Zhong L. u. a. 1997, S. 532).

Die Ständerspannungsgleichung wird im statorfesten Koordinatensystem numerisch integriert. Aus der Spannungs- und Strommessung lässt sich der Ständerfluss durch Integration der Spannung abzüglich des Spannungsabfalls am Statorwiderstand berechnen – Formel 19 –. Aus der vektoriellen Beziehung zwischen Strom und Fluss wird anschließend das elektromagnetische Drehmoment abgeleitet – Formel 20 –.

Folgende Zusammenhänge werden bei der Direct Flux and Torque Estimation verwendet:

$$\psi_s = \int (u_s - R_s i_s)\ dt \tag{19}$$

(Sadek u. a. 2022, S. 2326)

$$T(k) = \frac{3}{2} p \left\{ \varphi_D(k) i_Q(k) - \varphi_Q(k) i_D(k) \right\} \tag{20}$$

(Zhong L. u. a. 1997, S. 532)

Dabei bezeichnet $\vec{\psi}_s$ den Ständerfluss, $\vec{u}_s$ die Ständerspannung, $\vec{i}_s$ den Ständerstrom und R_s den Statorwiderstand. Das Drehmoment T_e wird auf Basis der Querkomponente zwischen Fluss- und Stromvektor berechnet.

Die Methode ist sehr kompakt und schnell anzuwenden. Sie verfügt über keine iterativen Schätzungen oder komplexe Modellierungen. Einfache Systeme ohne komplexe Anforderungen und mit geringen Ressourcen eignen sich für diese Methode. Aufgrund der Einfachheit ist sie jedoch empfindlich gegenüber Messfehlern (Sadek u. a. 2022, S. 2328). Daher wird die Methode oft in Kombination mit anderen Verfahren bzw. Filtermethoden verwendet.

Moderne Inverter verwenden die DFTE häufig für die direkte Drehmomentregelung (DTC).

3.5.2.6 Recursive Least Squares

Die Recursive-Least-Squares-Methode ist eine online-fähige Variante der klassischen Least-Squares-Methode – aus Kapitel 3.4.8 – mit dem Unterschied, dass es sich um ein kontinuierliches, rekursives Schätzverfahren handelt. Sie wird in der Antriebstechnik eingesetzt, um elektrische Maschinenparameter wie Rotorwiderstand R_r, Hauptinduktivität L_m oder Streuinduktivitäten L_σ dynamisch und in Echtzeit zu erfassen.

Bei der Offline-Variante – aus Kapitel 3.4.7 – wird das Verfahren nur einmal durchgeführt, während bei der Online-Recursive-Least-Squares-Methode das Verfahren laufend betrieben wird und die erfassten Parameter kontinuierlich aktualisiert werden. Bei jedem neuen Messwert wird die bisherige Schätzung angepasst. Somit gilt das Verfahren als dynamisches Verfahren und passt sich an Temperatur- oder Laständerungen an.

Der mathematische Grundgedanke ist derselbe wie bei der klassischen Least-Squares-Methode – aus Kapitel 3.4.7. Der quadratische Fehler zwischen gemessenen Größen und modellierten Größen wird minimiert, nur dass sich das Verfahren diesmal iterativ verhält.

Die folgenden Formeln 21 zeigen die typische rekursive Struktur:

$$\begin{cases} \hat{\theta}(N+1) = \hat{\theta}(N) + K(N+1)\big(y(N+1) - \varphi^T(N+1)\hat{\theta}(N)\big) \\ K(N+1) = P(N)\varphi(N+1)\Big[1 + \varphi^T(N+1)P(N)\varphi(N+1)\Big]^{-1} \\ P(N+1) = P(N) - K(N+1)\varphi^T(N+1)P(N) \end{cases} \tag{21}$$

(Tang u. a. 2018, S. 5)

Die Bedeutung der einzelnen Terme in den Formeln sowie der Ablauf der rekursiven Schätzung wurden bereits in Kapitel 3.4.7 erläutert.

Das Verfahren eignet sich gut zur Feinjustierung bereits ermittelter Maschinenparameter, die aus Self-Commissioning-Verfahren oder anderen einzelnen Verfahren stammen. In diesem Fall auch für Online-Verfahren – in Echtzeit und iterativ.

Moderne Inverter verfügen über das Recursive-Least-Squares-Verfahren, meist integriert im Self-Commissioning-Verfahren, und optimieren damit die meist offline bestimmten Parameter in Echtzeit.

3.5.3 Zusammenfassung der Online-Methoden

Zusammenfassend lässt sich feststellen, dass die Online-Parametererfassungsmethoden eine kontinuierliche Anpassung der Maschinenparameter während des Betriebs ermöglichen. Dabei werden sie in zwei Gruppen unterteilt: injektionsbasierte Verfahren und Observer-gestützte Verfahren. Die Gruppierung sowie alle zugehörigen Methoden und deren erfassten Parameter sind in Tabelle 6 dargestellt.

Injektionsbasierte Verfahren werden direkt als Methode angewendet, während Observer-gestützte Methoden eher Algorithmen sind, die zusätzlich zu Offline-Methoden angewendet werden. Bei der Auswahl ist es wichtig zu berücksichtigen, welche Parameter überhaupt erfasst werden müssen, ob Ergebnisse aus Offline-Methoden bereits vorliegen und verfeinert werden sollen oder ob keine Ergebnisse vorliegen und zunächst Strompulse injiziert werden müssen.

Je nach erforderlichen Maschinenparametern und Zustand der Maschine kann zwischen den Methoden in Tabelle 6 ausgewählt werden.

Tabelle 6: Übersicht der injektionsbasierten und observer-gestützten Online-Parametererfassungsverfahren

Verfahren	**Erfasste Parameter**	**Zustand der Maschine**
Injektionsbasierte Verfahren		
DC-Injektion	R_s	Sehr langsame Drehung
HF-Injektion	L_σ, θ_r	Niedrige Drehzahl
Rotating-Voltage-Injektion	θ_r	Niedrige Drehzahl
Pulsinjektion	θ_r	Beliebig / laufender Betrieb
Observer-gestützte Verfahren		
Luenberger-Observer	θ_r, ω_r	Mittlere bis hohe Drehzahl
Sliding-Mode-Observer	θ_r, ω_r	Mittlere bis hohe Drehzahl
MRAS	θ_r, ω_r	Mittlere bis hohe Drehzahl
Extended Kalman Filter	θ_r, ω_r	Gesamter Bereich
Direct Flux & Torque Estimation	Ψ_s, T_e	Mittlere Drehzahl
Recursive Least Squares	Feinjustierung der Verfahren aus dem Self-Commissioning-Verfahren	Mittlere bis hohe Drehzahl

3.6 Adaptive/Intelligente Methoden

Die adaptiv/intelligenten Methoden zur Parametererfassung unterscheiden sich darin von den anderen Methoden wie den Offline-Methoden (Kapitel 3.4) und Online-Methoden (Kapitel 3.5), dass sie nicht zwingend in einer bestimmten Situation angewendet werden müssen, also weder nur vor der Inbetriebnahme noch ausschließlich während des Betriebs, sondern adaptiv bzw. intelligent, also flexibel und anpassungsfähig eingesetzt werden können. Sie sind weder rein zustandsbasiert – wie bei Offline-Methoden – noch kontinuierlich messend – wie bei Online-Methoden –. Sie bestehen aus Algorithmen, regelbasierten Systemen oder lernenden Verfahren wie künstlicher Intelligenz, Fuzzy-Logik oder neuronalen Netzen.

Die adaptiven Methoden passen sich der Situation an und arbeiten je nach Kontext entweder wie eine Offline- oder wie eine Online-Methode. Adaptive Methoden benötigen meistens kein

Maschinenmodell. Sie nutzen Heuristik (Kaźmierkowski u. a. 2002, S. 368), Trainingsdaten (Tang u. a. 2018, S. 12–13; Cherif u. a. 2022, S. 902; Marulanda-Durango u. a. 2021, S. 1) – insbesondere bei auf künstlicher Intelligenz basierten Verfahren – oder mathematische Strukturen (Kaźmierkowski u. a. 2002, S. 353; Dewantoro und Kuo 2011, S. 884). Insbesondere bei komplexen Systemen mit nichtlinearem Verhalten, stark veränderlichen Betriebsbedingungen sind die adaptiven Methoden nützlich (Landau u. a. 2011, S. 1–2). Ein Nachteil von adaptiven Methoden ist, dass wenn Sie auf Trainingsdaten basieren, dass die Trainingsphasen sehr umfangreich sind, was wiederum kostenintensive Hochleistungshardware und/oder Software voraussetzt (Bose 2001, S. 643–644).

Zunehmend werden in modernen Inverter neben den Offline- und Online-Methoden auch die adaptiven Methoden eingesetzt. Sie ermöglichen dem Inverter die Feinjustierung und automatische Nachregelung der Maschinenparameter im laufenden Betrieb. In den folgenden Abschnitten werden die wichtigsten adaptiv-intelligenten Methoden vorgestellt, ihr Prinzip erläutert und ihr Einsatz im Kontext der automatisierten Parametererfassung durch Inverter analysiert.

3.6.1 Fuzzy-Logic-Controller

Die Fuzzy-Logic-Controller wurden ursprünglich für die Regelung nichtlinearer Systeme entwickelt. Sie sind modellfrei (Dewantoro und Kuo 2011, S. 884; Bose 2001, S. 576–577). Die Anwendung von Fuzzy-Systemen nimmt zu, insbesondere wenn andere Methoden nicht mehr ausreichend für eine präzise Parametrierung sind (Bose 2001, S. 577).

Im Vergleich zu den anderen modell- oder schätzungsbasierten Methoden besitzen Fuzzy-Systeme keine mathematischen Modelle (Bose 2001, S. 576). Bei Fuzzy-Systemen kommen Wenn-Dann-Regeln – If-Then-Rule – zum Einsatz (Kaźmierkowski u. a. 2002, S. 369; Bose 2001, S. 577–578). Ein Beispiel für diese Regeln ist: „Wenn Spannung konstant, dann Rotorwiderstand zu groß“. Durch solche Regeln ist es dem Inverter möglich, aus gemessenen Signalen bestimmte Maschinenparameter abzuleiten. Dadurch kann auch eine adaptive Korrektur von Statorwiderstand R_s ermöglicht werden (Karanayil u. a. 2005, S. 773).

Die Abbildung 17 zeigt eine beispielhafte Umsetzung eines Fuzzy-Logic-Controllers. Dabei wird der Statorwiderstand R_s bestimmt. Ein Referenzstrom I wird aus den Eingangssignalen V_s – Versorgungsspannung –, Rotorwinkelgeschwindigkeit ω_r und Flussverkettung mithilfe eines modellbasierten Beobachters berechnet. Dieser Referenzstrom wird mit dem gemessenen Statorstrom verglichen. Dabei entsteht ein Fehler $e(k)$. Dieser Fehler und dessen Änderung werden in den Fuzzy-Logic-Estimator eingespeist. Sie werden verarbeitet und durch die Wenn-Dann-Regeln wird eine Schätzung erzeugt. Somit wird der Statorwiderstand R_s durch den Fuzzy-Logic-Controller bestimmt.

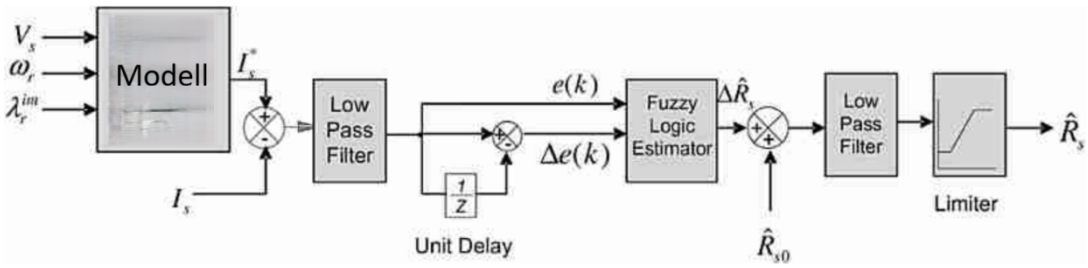

Abbildung 17: Bestimmung des Statorwiderstands R_s mithilfe eines Fuzzy-Logic-Controllers (Karanayil et al. 2005, S. 775)

Fuzzy-Systeme sind robust gegenüber Unsicherheiten und Störgrößen (Dewantoro und Kuo 2011, S. 884–887). Sie können über geeignete Regelmengen und Gewichtungen diese Abweichungen kompensieren und somit stabile Parameter liefern (Bose 2001, S. 576). Die Erstellung solcher Systeme – bzw. Regelwerke – ist jedoch kompliziert und nicht standardisiert. Die Genauigkeit ist begrenzt aufgrund der Methodik – es fehlt die Modellbildung und die Parametererfassung bzw. -schätzung basiert auf Wenn-Dann Regeln – und somit nur eingeschränkt anwendbar bei hochdynamischen komplexen Maschinenmodellen.

Fuzzy-Systeme bieten bei hochdynamischen Systemen eine flexible, aber unsichere Lösung für die Erfassung von Maschinenparametern. Sie eignen sich besser als Ergänzung zu den klassischen Verfahren. In der Praxis werden sie auch nur als Speziallösungen oder zur Ergänzung angewendet.

3.6.2 Support Vector Machines

Support Vector Machines benötigen keine vollständigen physikalischen Modelle. Sie basieren auf Machine Learning und somit auch auf Trainingsdaten (Marulanda-Durango u. a. 2021, S. 1; Cherif u. a. 2022, S. 901). Der Zusammenhang zwischen den Eingangs- und Ausgangsgrößen wird direkt aus diesen Daten abgeleitet und erlernt. Support Vector Machines werden bei komplexen nichtlinearen Systemen eingesetzt, besonders bei sich ändernden Betriebsbedingungen (Marulanda-Durango u. a. 2021, S. 1).

In Machine Learning werden SVMs dafür eingesetzt, Daten zu klassifizieren (Cherif u. a. 2022, S. 903–904; Jung 2024, S. 73–74) oder für Regressionsaufgaben verwendet (Jung 2024, S. 73). Die Parameteridentifikation einer elektrischen Maschine durch Inverter mit der Anwendung von SVMs funktioniert ähnlich. Zum Beispiel kann eine SVM trainiert werden, um Maschinenparameter aus messbaren Größen wie Spannung, Strom oder Drehzahl abzuleiten.

Eine einfache Übersicht ist in Abbildung 18 zu sehen. Sowohl vor dem Betrieb – Offline – als auch während des Betriebs – Online – ist eine Parametererfassung durch SVMs möglich. Moderne Invertersoftware verfügen über eine vorgelagerte Signalverarbeitung. Bei dieser Signalverarbeitung werden die erforderlichen Eingangsgrößen für die SVMs erfasst und weiter an

sie geleitet, damit aus diesen Eingangsgrößen die SVMs die erforderlichen Parameter bestimmen können (Marulanda-Durango u. a. 2021, S. 3).

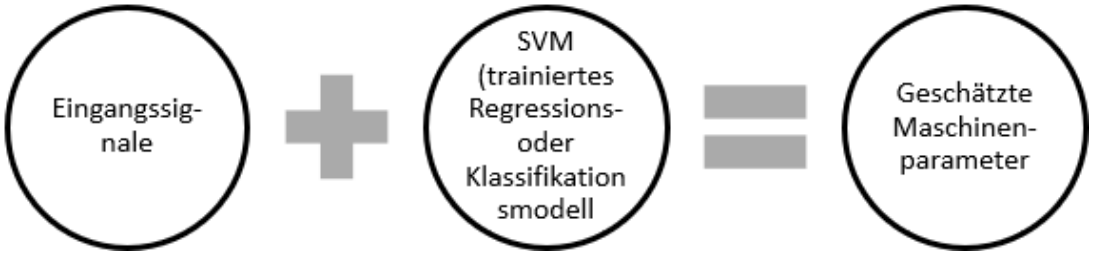

Abbildung 18: Einfache Darstellung der Logik von SVM bei der Parametererfassung

Ein Vorteil dieser Methode ist die Robustheit gegenüber Rauschen (Marulanda-Durango u. a. 2021, S. 3). Zudem können nichtlineare Zusammenhänge exakt modelliert werden – weil sie aus dem Zusammenhang der Trainingsdaten abgeleitet werden können. SVM‘s werden dynamisch aktualisiert, was die Änderung der Maschinenparameter im Betrieb ermöglicht.

Ein Nachteil ist die geringe Aussagekraft bei zu wenigen und/oder bei korrupten Trainingsdaten. Bei fehlenden Trainingsdaten ist gar keine Aussage möglich. Bei Inverter mit geringer Embedded-System-Speicher können zu große Datensätze zu Speicherproblemen führen.

Insgesamt lässt sich sagen, dass SVMs bei Verfügbarkeit von Trainingsdaten eine robuste Erfassung von Maschinenparametern ermöglichen, insbesondere in dynamischen oder schwer modellierbaren Szenarien, also in modernen Invertersystemen.

3.6.3 Genetic Algorithms

Genetic Algorithms – Genetische Algorithmen – gehören zu den evolutionären Optimierungsverfahren. Das Prinzip der genetischen Algorithmen ist von den biologischen Prinzipien der natürlichen Selektion inspiriert (Konstantinos T. Kampisios 2009, S. 58). Das heißt, es werden keine mathematischen Modelle benötigt. Eine Zielfunktion wird als Vergleich der geschätzten Parameter mit den gemessenen Parametern definiert und verfolgt (Konstantinos T. Kampisios 2009, S. 65). Genetic Algorithms eignen sich besonders für komplexe, nichtlineare Optimierungsprobleme (Konstantinos T. Kampisios 2009, S. 56–57) – wie zum Beispiel bei schwer modellierbaren elektrischen Maschinen oder unter dynamischen Betriebsbedingungen.

Bei der Parametererfassung durch Invertersoftware werden durch Genetic Algorithms Maschinenparameter wie Statorwiderstand R_s, Rotorwiderstand R_r, Statorinduktivität L_s bestimmt (Konstantinos T. Kampisios 2009, S. 121–123) , indem gemessene Maschinendaten wie Strom I, Spannung U oder Drehzahl n durch mehrere Iterationen weiterentwickelt werden, bis die zu Beginn definierte Zielfunktion erreicht wird (Konstantinos T. Kampisios 2009, S. 10).

Die Abbildung 19 zeigt den Ablauf eines Genetic-Algorithmus. Für die Parametererfassung elek-

trischer Maschinen durch Inverter wird der gleiche Ablauf angewendet. Zu Beginn wird eine Startpopulation erzeugt. Jedes Individuum stellt eine mögliche Kombination von Maschinenparametern dar. Danach wird die Fitness – Eignung – jedes Kandidaten bewertet. Anschließend wird geprüft, ob die Optimierungskriterien erfüllt sind. Wenn ja, werden die Parameter aus den besten Individuen bestimmt. Wenn nicht, wird in drei Schritten eine neue Population erzeugt:

1. Selektion: Auswahl der am besten geeigneten Individuen
2. Crossover: Kombination von Parametern
3. Mutation: Zufällige Veränderung der Parameter zur Erhöhung der Vielfalt

Die neu erzeugte Population wird erneut bewertet, bis die besten Lösungen vorliegen.

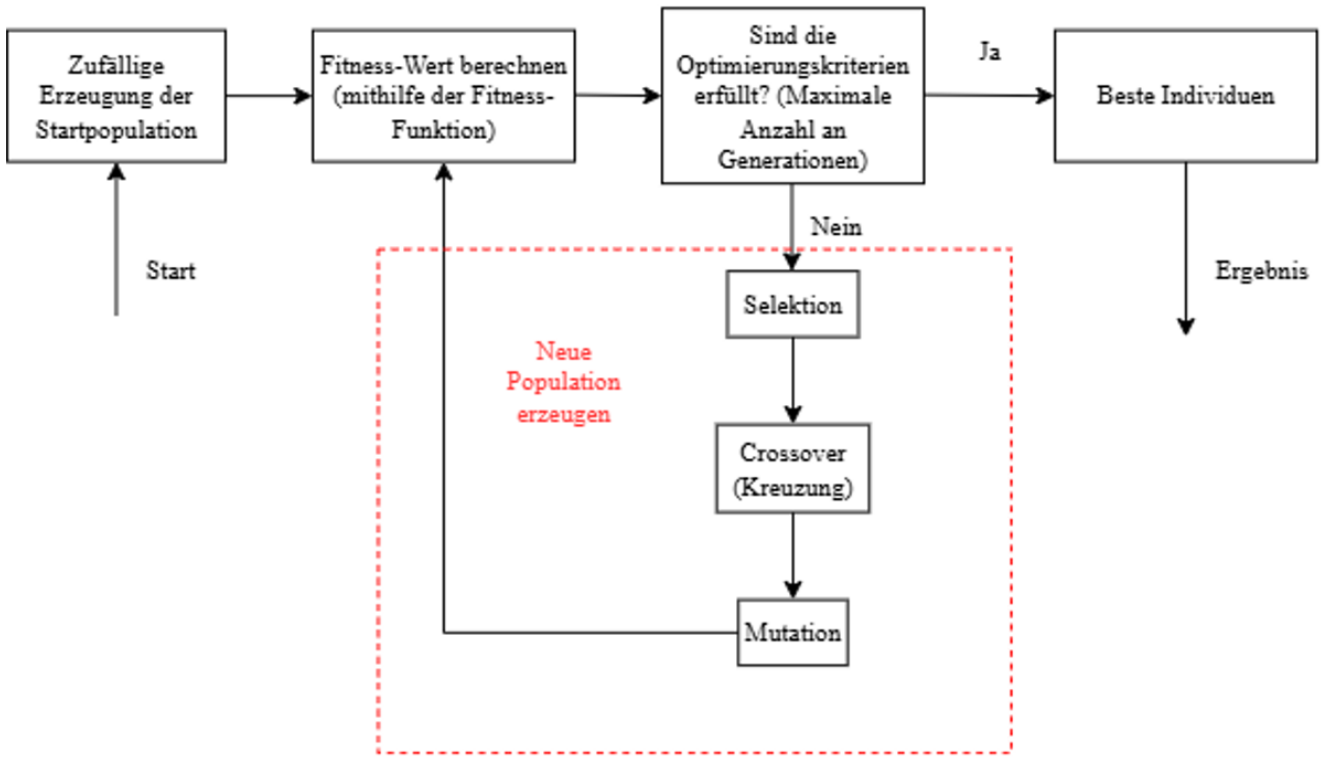

Abbildung 19: Ablauf eines Genetic-Algorithmus zur Parametererfassung elektrischer Maschinen (Konstantinos T. Kampisios 2009, S. 60)

Bei hochkomplexen und dynamischen Maschinenverhalten mit vielen unbekannten Parametern ist die Genetic-Algorithms-Methode besonders von Vorteil, weil sie auch bei verrauschten und/oder unvollständigen Datensätzen sinnvolle Parameterlösungen finden kann (Konstantinos T. Kampisios 2009, S. 57). Auf der anderen Seite ist die Genetic-Algorithms-Methode sehr rechenintensiv und nicht geeignet für Systeme mit begrenzter Hardware oder Rechenleistung. Aus diesen Gründen werden sie meist als Ergänzung zu den klassischen Methoden angewendet, um erfasste Parameter zu verfeinern.

Moderne Inverter setzen Genetic Algorithms als Teillösung ein. Das heißt, als Feinjustierung

nur dort, wo Unsicherheit und Nichtlinearität herrschen, oder als Parametererfassungsmethode, wenn die Maschinenparameter nicht mit anderen Methoden erfasst werden können (Konstantinos T. Kampisios 2009, S. 79–80, 166).

3.6.4 GPSO/PSO

Particle Swarm Optimization (PSO) oder Global Particle Swarm Optimization (GPSO) sind populationsbasierte, stochastische Verfahren, die von kollektivem Verhaltensmuster der Natur inspiriert sind (Elrachid u. a. 2021, S. 1; Li Liu u. a. 2007, S. 2955–2956). Während PSO lokale Optimierungen vornimmt, finden die Optimierungen bei GPSO durch globale Informationen innerhalb der gesamten Population statt (Sanjay und Pidaparti 2016, S. 2). Beide Verfahren sind modellfreie Optimierungsalgorithmen und werden immer häufiger für die Parametererfassung elektrischer Maschinen durch Inverter eingesetzt.

Eine Menge virtueller „Teilchen“ wird definiert – z. B. Rotorwiderstand R_s, Induktivität L oder Zeitkonstanten τ – und zufällig initialisiert. Die Position und Geschwindigkeit dieser Teilchen werden iterativ angepasst. Dabei werden die besten bisher gefundenen Lösungen – des Teilchens und die der gesamten Schwarmpopulation – kombiniert (Elrachid u. a. 2021, S. 3; Li Liu u. a. 2007, S. 2956–2957). Moderne Inverter nutzen dieses Verfahren für die Bestimmung von Maschinenparametern wie Statorwiderstand R_s aus Maschinendaten wie Spannungs-, Strom- oder Drehzahlsignalen (Li Liu u. a. 2007, S. 2958). Eine Zielfunktion wird definiert, die den Fehler zwischen einem Simulationsmodell mit Testparametern und den real gemessenen Daten minimiert. Wie vorhin erklärt, fliegen die Partikel durch den Lösungsraum. Sie nähern sich durch jede Iteration der optimalen Parametrierung (Li Liu u. a. 2007, S. 2957; Elrachid u. a. 2021, S. 3).

Die Abbildung 20 zeigt den schematischen Ablauf eines PSO/GPSO-Algorithmus zur Parametererfassung elektrischer Maschinen. Zunächst werden die Optimierungsparameter initialisiert. Diese Parameter sind z. B. Wertebereiche sämtlicher Maschinenparameter. Danach werden virtuelle Teilchen zufällig im Suchraum verteilt.

Die Fitness wird bewertet über eine Zielfunktion. Diese Zielfunktion minimiert den Unterschied zwischen gemessenen Maschinensignalen. Für jedes Teilchen wird die persönlich beste Lösung gespeichert. Gruppenführer und ein globaler Führer werden bestimmt. Die Geschwindigkeit jedes Teilchens wird angepasst und die Position aktualisiert. Der Prozess wiederholt sich, bis ein Abbruchkriterium erreicht ist. Die dabei ermittelten besten Parameter ergeben die gesuchten Maschinenparameter.

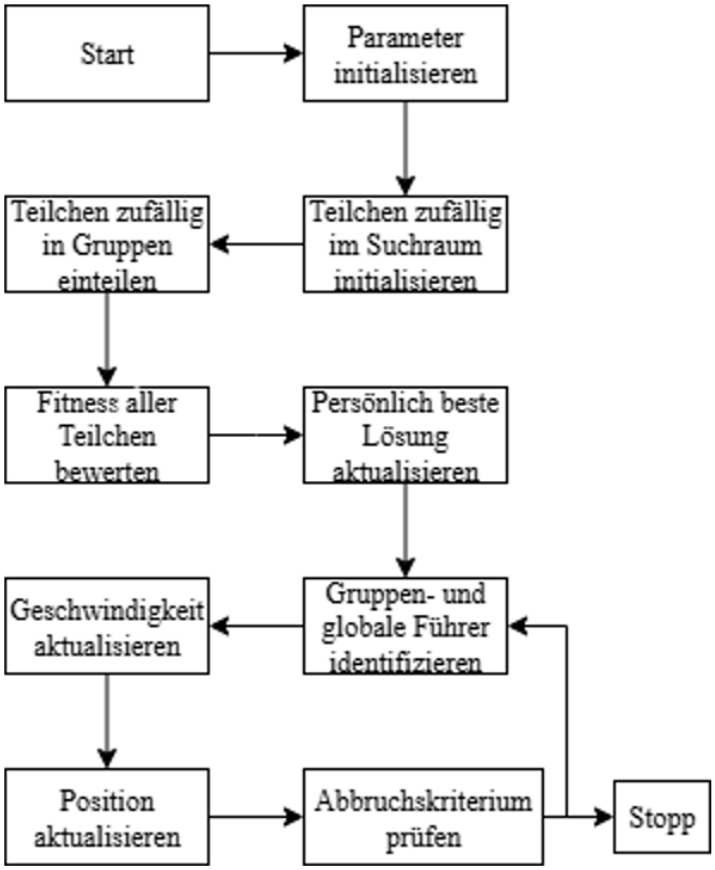

Abbildung 20: Schematische Darstellung der Parameterschätzung mit PSO/GPSO(Sanjay und Pidaparti 2016, S. 3)

PSO und GPSO können auch bei fehlender Modellstruktur eingesetzt werden und haben eine hohe Effizienz. Ein Nachteil ist wie bei anderen heuristischen Verfahren der Rechenaufwand und somit auch die Anforderung an hohe Rechenleistung. Bei Hardware mit begrenzter Leistung kann das Verfahren nur als ergänzende Methode eingesetzt werden.

Moderne Inverter nutzen PSO und GPSO als ergänzende Methode zu den klassischen Methoden. Sie dienen als Feinjustierung.

3.6.5 Differential Evolution

Differential Evolution ist ein weiteres evolutionäres Optimierungsverfahren. Es gehört zu den heuristischen und modellfreien Verfahren (Guedes u. a. 2017, S. 206). Wie auch bei den anderen heuristischen Verfahren eignet es sich besonders gut zur Schätzung von Maschinenparametern in hochdimensionalen, verrauschten oder nichtlinear modellierbaren Systemen (Guedes u. a. 2017, S. 211). Es ist – wie auch bei den anderen adaptiven Verfahren – iterativ, und die Lösungen werden weiterentwickelt.

Maschinenparameter wie Statorwiderstand R_s, Rotorwiderstand R_r und Leckinduktivitäten L_σ werden gleichzeitig bearbeitet (Guedes u. a. 2017, S. 205). Dafür erzeugte Lösungen werden ver-

glichen und die bessere Lösung wird ausgewählt. Dadurch werden optimale Lösungen gefunden ohne Modelle zu erstellen oder Ableitungen zu berechnen.

Abbildung 21 zeigt den typischen Ablauf eines Differential-Evolution-Algorithmus. Im Prinzip ist er identisch mit dem Genetic Algorithms – aus Kapitel 3.6.3 –, mit dem Unterschied, dass sich die Reihenfolge der Verfahren bei der Erzeugung einer neuen Population umgekehrt hat. Es erfolgt zuerst eine Mutation, danach ein Crossover und anschließend eine Selektion.

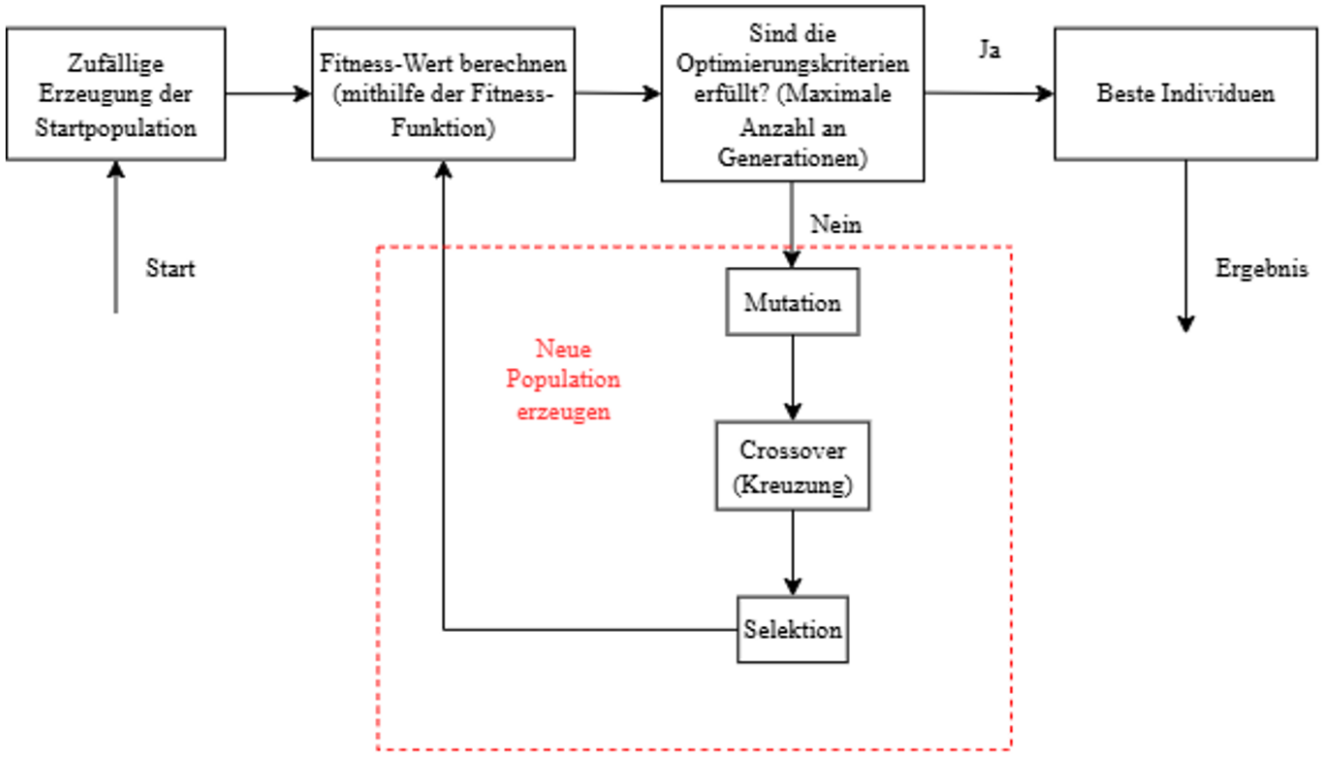

Abbildung 21: Ablauf eines Differential-Evolution-Algorithmus zur Parametererfassung elektrischer Maschinen(Guedes u. a. 2017, S. 206)

Differential Evolution hat eine geringe Komplexität und ist robust gegenüber Rauschen und Nichtlinearität. Wie auch bei den anderen heuristischen Verfahren ist Differential Evolution für modellfreie Systeme zur Feinjustierung gut geeignet. Auch Systeme ohne vollständiges Maschinenmodell sind gute Kandidaten für Differential Evolution.

Aufgrund der hohen Anforderungen an Rechenleistung ist die Methode nicht geeignet für Systeme mit begrenzter Hardwareleistung – z.B. schwache Embedded-Systeme –.

Moderne Inverter nutzen Differential Evolution meist als Ergänzung, zur Feinjustierung oder für Parameter, die mit klassischen Methoden nicht ermittelbar sind.

3.6.6 Neuronale Netze

Neuronale Netze sind Methoden, die vom biologischen Nervensystem des menschlichen Gehirns inspiriert sind (Bose 2001, S. 625). Sie sind modellfrei. Sie sind ein Grundbaustein des Machine Learning und eines der wichtigsten Verfahren für die Abbildung nichtlinearer Zusammenhänge. Neuronale Netze werden immer häufiger für die Parametererfassung elektrischer Maschinen eingesetzt (Schröder und Böcker 2021, S. 1138) – insbesondere wenn die klassischen Verfahren allein nicht ausreichend sind oder kein vollständiges Maschinenmodell verfügbar ist.

Maschinendaten wie Strom I, Spannung U oder Drehzahl n werden als Eingangsgrößen definiert, die gesuchten Maschinenparameter als Ausgangsgrößen. Diese Maschinenparameter werden aus vorhandenen Datensätzen zusammen mit den Eingangsgrößen approximiert. Der Trainingsprozess kann sowohl vor der Inbetriebnahme – Offline –, was häufiger der Fall ist, als auch während des Betriebs – Online – durchgeführt werden. Fehlerfunktionen und Rückpropagation passen dabei die Gewichte des Netzes während des Betriebs iterativ an und sorgen so für bessere Ergebnisse. Ein trainiertes Netz kann aus Eingabedaten die entsprechenden Maschinenparameter ableiten (Karanayil u. a. 2005, S. 771–773; Schröder und Böcker 2021, S. 1138–1140).

Abbildung 22 zeigt den schematischen Aufbau eines neuronalen Netzes zur Parametererfassung elektrischer Maschinen. Ein neuronales Modell der Asynchronmaschine bekommt die gleichen Eingangssignale wie die reale Maschine. Danach werden die Ausgangsgrößen des Modells mit den gemessenen Werten der realen Maschine verglichen. Die Differenz wird über ein Backpropagation-Verfahren genutzt, um die Gewichte des Netzes zu korrigieren. Das Netz lernt, aus Eingangsdaten die Maschinenparameter korrekt abzuleiten.

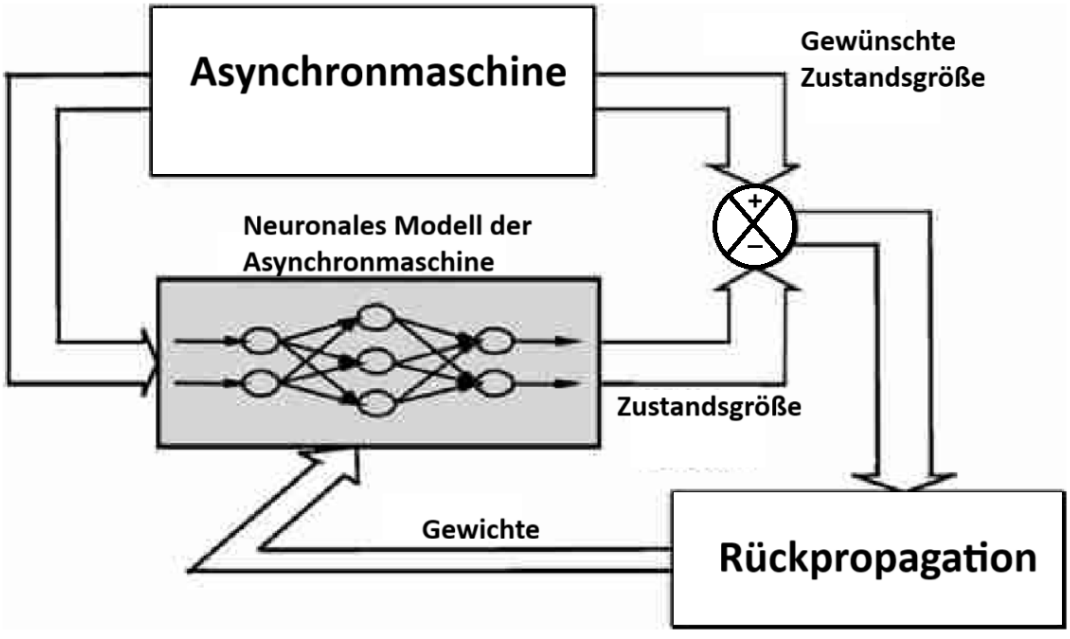

Abbildung 22: Neuronales Netz zur Schätzung von Maschinenparametern durch Rückpropagation(Karanayil u. a. 2005, S. 772)

Neuronale Netze bilden hochgradig nichtlineare Zusammenhänge ab (Schröder und Böcker 2021, S. 1137). Sie sind besonders flexibel aufgrund ihrer Einsetzbarkeit bei verschiedenen Betriebszuständen. Auf der anderen Seite benötigen neuronale Netze starke und vollständige Datensätze, um möglichst präzise Maschinenparameter bestimmen zu können. Unzureichende Datensätze können zu Abweichungen führen.

Moderne Inverter nutzen neuronale Netze bei Maschinen mit komplexem, nichtlinearem Verhalten und stark veränderlichen Betriebsbedingungen.

3.6.7 Zusammenfassung der adaptiv/intelligenten Methoden

Die folgende Tabelle 7 schafft Übersicht und Verständnis zu den einzelnen adaptiv/intelligenten Parametererfassungmethoden. Klassifiziert wurde nach den erfassten Parametern, der Art der Methode, der Linearität des Problems – z.B. der elektrischen Maschine –, der Tauglichkeit für hochdynamische Systeme, der Robustheit gegenüber Unsicherheiten und dem Aufwand der Methode.

Tabelle 7: Übersicht der adaptiv/intelligenten Methoden zur Parametererfassung

Verfahren	**Parameter**	**Art der Methode**	**Linear.**	**hochdyn. Systeme**	**Rob.**	**Aufw.**
Fuzzy-Logic-Controller	R_s	Heuristisch, modellfrei	Nichtlin.	Begrenzt	Ja	Mittel
Support Vector Machines	Je nach Trainingsdaten	Machine Learning, modellfrei	Lin./ Nichtlin.	Gut	Ja	Hoch
Genetic Algorithms	R_s, R_r, L_s	Evolutionär, modellfrei	Nichtlin.	Gut	Ja	Hoch
GPSO / PSO	R_s, R_r, L_s	Evolutionär, modellfrei	Nichtlin.	Begrenzt	Ja	Hoch
Differential Evolution	R_s, L_σ	Evolutionär, modellfrei	Nichtlin.	Ja	Ja	Hoch
Neuronale Netze	Je nach Trainingsdaten	Machine Learning, modellfrei	Nichtlin.	Ja	Ja	Hoch

Zusammenfassend lässt sich feststellen, dass die adaptiven/intelligenten Verfahren sich generell gut eignen für die Parametererfassung elektrischer Maschinen bei veränderlichen Betriebszuständen und/oder bei fehlendem Maschinenmodell. Sie unterscheiden sich jedoch in ihrer Eignung für bestimmte Situationen und Anforderungen.

Fuzzy-Logic-Controller sind am besten geeignet, wenn nur wenige Messgrößen vorliegen. Wenn Störungen und Unsicherheiten kompensiert werden müssen, aber keine hohe Genauigkeit gefordert ist, sind sie ideal einsetzbar. Support Vector Machines sind vorteilhaft, wenn genügend Trainingsdaten vorhanden sind. Sie eignen sich für komplexe Systeme.

Genetic Algorithms, GPSO/PSO und Differential Evolution sind besonders nützlich, wenn Maschinenparameter schwer zugänglich oder stark verrauscht sind. Sie unterscheiden sich in der Tauglichkeit für hochdynamische Systeme.

Neuronale Netze sind ideal, wenn große Datenmengen verfügbar sind und hochgradig nichtlineare Zusammenhänge abgebildet werden müssen. Allerdings sind sie stark abhängig von der Qualität der Trainingsdaten.

Insgesamt zeigt sich:

- Für einfache Anwendungen mit Unsicherheiten = Fuzzy-Logic-Controller
- Für datenreiche, komplexe Systeme = SVMs oder Neuronale Netze
- Für nichtlineare, verrauschte Szenarien ohne Modell = Genetic Algorithms, PSO/GPSO oder Differential Evolution
- Für leistungsfähige Inverterhardware und lernfähige Systeme = Neuronale Netze als flexibelste Lösung.

Damit ergänzen sich die Methoden gegenseitig: Während heuristische Verfahren vor allem bei fehlenden Modellen oder unsicheren Bedingungen sinnvoll sind, liefern datengetriebene Ansätze die besten Ergebnisse, wenn ausreichend Informationen vorhanden sind.

3.7 Vergleich der Methoden zur Parametererfassung elektrischer Maschinen und Auswahlkriterien

Parametererfassungsmethoden elektrischer Maschinen, unterteilt in Offline-, Online-, und adaptive/intelligente Methoden durch Inverter, wurden in Tabelle 8 durch sämtliche Bewertungskriterien bewertet. Dabei wurde berücksichtigt, welche Methodengruppen wann, wie aufwendig, wie genau, wie robust arbeiten und wie flexibel sie eingesetzt werden können.

Tabelle 8: Vergleichstabelle zur Übersicht der Methoden zur Parametererfassung elektrischer Maschinen

Kriterium	**Offline-Methoden**	**Online-Methoden**	**Adaptive/Intelligente Methoden**
Anwendung	Vor der Inbetriebnahme	Während des Betriebs	Flexibel
Messaufwand	Hoch	Mittel	Gering
Rechenaufwand	Gering bis mittel	Mittel bis hoch	Hoch
Genauigkeit	Hoch	Mittel bis hoch	Hoch (abhängig von Datenmenge)
Modell erforderlich	Ja	Ja	Nein
Robustheit gegen Störungen	Mittel	Mittel bis hoch	Hoch
Flexibilität	Gering	Mittel	Hoch
Serienimplementierung	Üblich	Teilweise	Selten
Beispielverfahren	Gleichstromversuch	MRAS	Neuronale Netze

Aus der Bewertung ergeben sich einige charakteristische Unterschiede:

- Rechenaufwand: Während Offline- und Online- Methoden einen mittleren Rechenaufwand erfordern, brauchen adaptive/intelligente Methoden – abhängig von der Größe der verfügbaren Datensätze – eine hohe und/oder extreme Rechenleistung und somit starke bis sehr starke Hardware.
- Messaufwand: Offline-Methoden erfordern oft Messaufbauten; auch bei Self-Commissioning-Verfahren werden Messaufbauten benötigt, obwohl das Verfahren automatisiert durchgeführt wird. Bei Online-Methoden hingegen werden lediglich die Sensorsignale als Eingangssignale benötigt. Adaptive/intelligente Methoden erfordern ausschließlich die Daten aus den Sensoren als Eingang.
- Robustheit: Adaptive/intelligente Methoden sind besonders robust gegenüber Unsicherheiten und Störungen. Offline-Methoden hingegen sind störanfällig gegen Störungen, da sie die Parameter nicht dynamisch bestimmen, sondern nur einmal vor der Inbetriebnahme.
- Flexibilität: Adaptive/intelligente Methoden bieten die höchste Flexibilität. Sie können je nach Verfügbarkeit und Situation schnell angepasst werden.

- Modellabhängigkeit: Bei adaptiven/intelligenten Methoden sind keine Maschinenmodelle erforderlich.

3.7.1 Entscheidungskriterien für die Auswahl geeigneter Verfahren

In der Praxis ist es häufig sinnvoll, mehrere Methoden zu kombinieren. Dadurch kann eine präzise und den Anforderungen entsprechende Kombination von Methoden erzeugt werden. Beispielsweise kann für die erste Parametrierung eine Offline-Methode angewendet werden und danach für eine Feinjustierung eine Online- oder adaptive/intelligente Methode eingesetzt werden. Moderne Inverterlösungen bieten bereits integrierte Softwarelösungen, die genau diese Kombination je nach Anforderung vereinen und die erforderlichen Maschinenparameter ausliefern.

Die Auswahl eines geeigneten Verfahrens zur Parameterbestimmung elektrischer Maschinen hängt von verschiedenen Faktoren ab. Die folgenden Faktoren sind bei der Auswahl die wichtigsten und entscheidenden Kriterien:

- Verfügbarkeit eines Modells: Wenn kein Maschinenmodell vorliegt, sind modellfreie Methoden wie die adaptiven/intelligenten Methoden anzuwenden.
- Zeitpunkt der Parametrierung: Wenn eine Parametrierung ohne Last oder mit verfügbaren bekannten Daten möglich ist, kann eine Offline-Methode durchgeführt werden. Muss im laufenden Betrieb dynamisch gearbeitet werden, sind Online-Methoden anzuwenden.
- Verfügbare Rechenleistung: Bei fehlender oder niedriger Rechenleistung können manche Online- und adaptiven-/intelligenten- Methoden nicht angewendet werden.
- Erwartete Betriebsbedingungen: Bei stark schwankenden Bedingungen, d. h. bei vielen vorkommenden Störungen, sind die adaptiven/intelligenten Methoden zu bevorzugen.
- Geforderte Genauigkeit: Je nach der erforderlichen Genauigkeit werden Methoden entsprechend kombiniert.

Die Entscheidungskriterien basieren auf den wichtigsten Eigenschaften der bisher vorgestellten und behandelten Verfahren zur Parameterbestimmung elektrischer Maschinen. Aus diesen Eigenschaften wurden die Kriterien systematisiert und erstellt. Sie dienen der praxisorientierten Auswahl von Methoden und können in verschiedensten Fällen zur Orientierung dienen. Außerdem ist der Entscheidungsbaum in Abbildung 23 eine schnelle Methodik, um eine geeignete Wahl von Parametererfassungsmethoden zu treffen. In dem Entscheidungsbaum kann ausgewählt werden, ob offline, online oder adaptiv/intelligent erfasst wird. Nach der Auswahl können die spezifischen Methoden aus den jeweiligen Zusammenfassungen der Kapitel Offline – Kapitel 3.4 –, Online – Kapitel 3.5 – und adaptiv/intelligent – Kapitel 3.6 – ausgesucht und angewendet werden.

Beispiele zur praxisorientierten Auswahl folgen unten:

- Fall 1: Die Maschine verfügt über ein gutes Modell, aber der Inverter hat begrenzte Rechenleistung. Dann wird eine Offline-Methode bevorzugt.
- Fall 2: Kein Modell vorhanden, stark veränderliche Bedingungen. Eine adaptive/intelligente Methode wird bevorzugt.
- Fall 3: Die ersten Maschinenparameter wurden durch Offline-Methoden schon erfasst, aber die Betriebsbedingungen sind stark veränderlich. Dann wird zusätzlich noch eine Online- oder adaptive/intelligente Methode angewendet zur Feinjustierung der bereits erfassten Maschinenparameter.

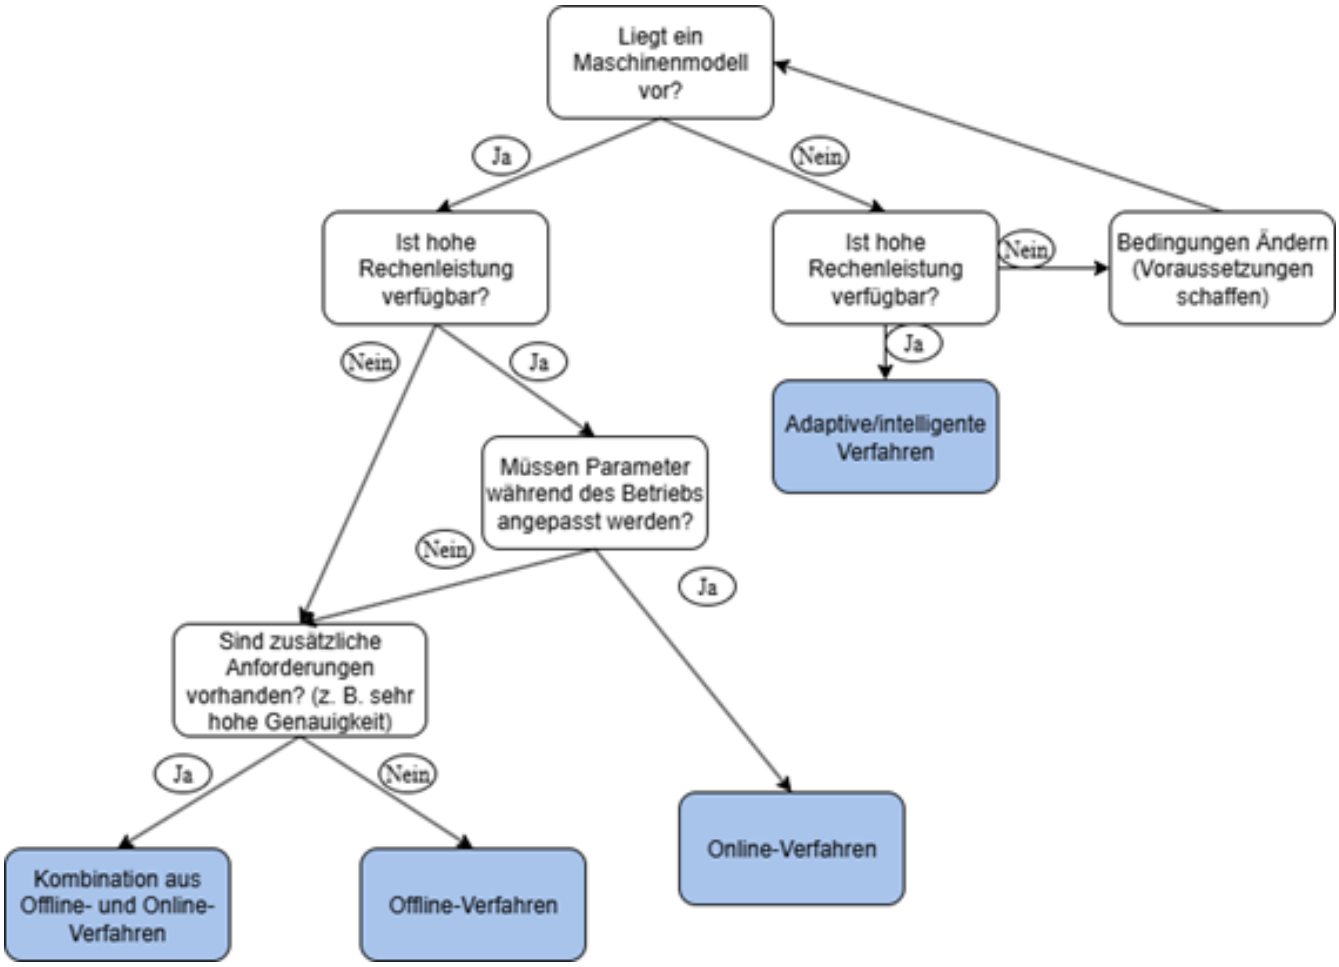

Abbildung 23: Entscheidungsbaum zur Auswahl der Oberkategorie einer geeigneten Parametererfassungsmethode

In der Industrie wird typischerweise durch ein geeignetes Inverter-Software zunächst ein Self-Commissioning-Prozess durchgeführt – Der Name des Prozesses variiert je nach Hersteller –. Dadurch werden die ersten Maschinenparameter schon bestimmt. Meistens sind diese Parameter aber ungenau oder verändern sich im Laufe des Betriebs. Dafür kommen zusätzlich Online- oder

adaptive/intelligente Verfahren zum Einsatz.

4 Marktanalyse aktueller Inverter-Software

In diesem Kapitel wird eine Marktanalyse aktueller Inverter-Software durchgeführt. Ziel ist es, aktuelle moderne Inverter-Software auf dem Markt, die in der Praxis angewendet werden, zu identifizieren und diese Inverter-Software zu analysieren.

Die bisherigen Verfahren zur Parametererfassung elektrischer Maschinen durch Inverter-Software, die in dieser Arbeit behandelt wurden – Kapitel 3 –, werden in diesem Kapitel gegenübergestellt und mit den Inverter-Software-Produkten aus der Praxis verglichen. Es wird analysiert, wie diese Inverter-Software die Methoden zur Parametererfassung einer elektrischen Maschine umsetzt. Dabei werden auch die Inverter-Software-Produkte miteinander verglichen und bewertet.

4.1 Marktanalysemethode

Die vorliegenden Inverter-Software wurde durch die Sekundärforschungsmethode analysiert (Bruhn 2024, S. 103). Es wurden Fachbücher, wissenschaftliche Artikel, Patentschriften sowie Herstellerdokumentationen gefunden und die Inverter-Software auf dem Markt festgestellt sowie ausgewertet.

Außerdem stützt sich die Analyse auf die Webseiten der führenden Inverteranbieter wie Siemens, ABB und Danfoss.

4.2 Siemens SINAMICS

Siemens bietet für die Industrie die SINAMICS-Frequenzumrichter (Siemens AG 2009, S. 15; Siemens AG 2025a). SINAMICS von Siemens zählt zu den am häufigsten eingesetzten Inverter-Systemen in der Industrie (Salgarkar 2024; *Frequency inverter market* 2017). SINAMICS kommt in verschiedenen Anwendungen zum Einsatz – auch für die Parametererfassung elektrischer Maschinen (Siemens AG 2009, S. 15).

Für die Parametrierung elektrischer Maschinen bietet SINAMICS mehrere Funktionen, aber hauptsächlich Offline-Methoden. Das heißt, SINAMICS eignet sich besonders gut für die Parametrierung vor der Inbetriebnahme einer elektrischen Maschine. Außerdem bietet SINAMICS als Nebenfunktion die Möglichkeit, die Parameter der elektrischen Maschine während des Betriebs zu überwachen. Dementsprechend kann der Inverter die Parameter auch unter veränderlichen, dynamischen Bedingungen, während des Betriebs aktualisieren bzw. überschreiben (Siemens AG 2012; Siemens AG 2009; Siemens AG 2016). Die folgenden Verfahren werden bei SINAMICS zur Parametrierung eingesetzt:

- Motoridentifikation / Self-Commissioning: Das Self-Commissioning/Motorenidentifikationsverfahren ist das zentrale und wichtigste Verfahren bei SINAMICS. Die Motoridentifikation erfolgt über den Software-Code p1900, das Self-Commissioning über p1910 (Siemens AG 2016, S. 235). Bei der Motoridentifikation werden die Parameter der elektrischen Maschine automatisiert erfasst (Siemens AG 2016, S. 231–240). Diese Identifikation erfolgt im Stillstand (Siemens AG 2016, S. 235). Dieses Verfahren entspricht dem Standstill-Identification-Verfahren aus dem Kapitel 3.4.6 oder dem Self-Commissioning-Verfahren aus dem Kapitel 3.4.8, je nach Umfang und Bedarf an Parameter. Es kann sowohl nur ein Teil des Verfahrens durchgeführt werden – z. B. nur Standstill-Identification – als auch das vollständige Self-Commissioning-Verfahren je nach Bedarf an Maschinenparameter. Es beinhaltet auch die Gleichstrom- und Kurzschlussversuche aus den Kapiteln 3.4.2 und 3.4.4. Dieses Verfahren kann den Statorwiderstand R_s , Sättigungscharakteristiken und die Rotorzeitkonstante T_r bestimmen (Siemens AG 2004, S. 251). Je nach Motorentyp können auch weitere Maschinenparameter erfasst werden. Abbildung 24 verschafft eine Übersicht zu diesen Parametern.

	Asynchronmotor	Permanenterregter Synchronmotor
p1910 = 1	• Ständerwiderstand (p0350) • Läuferwiderstand (p0354) • Ständerstreuinduktivität (p0356) • Läuferstreuinduktivität (p0358) • Hauptinduktivität (p0360) • Umrichter Ventilschwellspannung (p1825) • UmrichterVentilverriegelungszeiten (p1828 ... p1830)	• Ständerwiderstand (p0350) • Ständerinduktivität q-Achse (p0356) • Ständerinduktivität d-Achse (p0357) • Umrichter Ventilschwellspannung (p1825) • Umrichter Ventilverriegelungszeiten (p1828 ... p1830)

Abbildung 24: Übersicht der erfassten Maschinenparameter bei p1910 = 1 (Self-Commissioning)(Siemens AG 2009, S. 33)

- Rotierende Messzyklen: Die drehende Messung erfolgt über den Software-Code p1960 (Siemens AG 2016; Siemens AG 2009, S. 35). Weitere Eigenschaften der Maschine wie z. B. das magnetische Sättigungsverhalten oder das Trägheitsmoment J (Siemens AG 2009, S. 35) werden durch rotierenden Messzyklen erfasst. Das entspricht dem Rampentest aus Kapitel 3.4.5.

Im Vergleich zu den in Kapitel 3 behandelten Parametererfassungsmethoden wird deutlich, dass SINAMICS hauptsächlich Offline-Methoden bzw. Automatisierte Verfahren einsetzt. Die Anwendung von Online-Methoden wird in den Dokumenten nicht direkt erwähnt, aber es ist davon auszugehen, dass sie angewendet werden, da sonst die Echtzeitüberwachung und Aktualisierung der Parameter in Echtzeit nicht möglich ist. Adaptive/intelligente Methoden werden nicht eingesetzt.

Tabelle 9 bietet eine Übersicht zu den in SINAMICS eingesetzten Parametererfassungsmethoden

und die entsprechenden Kapitel bzw. behandelten Verfahren aus dieser Arbeit.

Tabelle 9: Vergleich von SINAMICS-Verfahren zur Parametererfassung

SINAMICS-Verfahren	Verfahren aus Kapitel
Motoridentifikation / Self-Commissioning (p1900 / p1910)	3.4.7 Standstill Identification, 3.4.9 Self-Commissioning
Rotierende Messung (p1960)	3.4.6 Rampentest / Low-Speed Test

4.3 ABB ACS880

Der Inverterhersteller ABB bietet für die Industrie verschiedene Frequenzumrichter-Modelle an (ABB Group 2025a). ABB zählt zu den am häufigsten eingesetzten Inverter-Systemen in der Industrie (Salgarkar 2024; *Frequency inverter market* 2017). In dieser Arbeit wird das ACS880-Frequenzumrichter-Modell behandelt. In verschiedenen Anwendungen kommt der ACS880 zum Einsatz (ABB Group 2025b, S. 4). Auch für die Erfassung von Maschinenparametern elektrischer Maschinen (ABB Group 2013, S. 13).

Für die Parametererfassung elektrischer Maschinen liegt der Fokus des ACS880 auf Offline-Methoden. Aus diesem Grund eignet sich der ACS880 besonders gut für die Parametererfassung vor der Inbetriebnahme einer elektrischen Maschine. Zusätzlich verfügt er über Funktionen, die zur Überwachung und gegebenenfalls Aktualisierung der Parameter dienen, je nach Bedarf und den Betriebsbedingungen. Die folgenden Verfahren bzw. Funktionen werden im ACS880 zur Parametrierung eingesetzt:

- ID-Run: Der ACS880 verfügt über die Funktion „ID-Run"(ABB Group 2013, S. 13). Der ID-Run ist im Prinzip sehr ähnlich zur Motoridentifikationsfunktion von SINAMICS – Kapitel 4.2 –. Es handelt sich um ein automatisiertes Verfahren zur Erfassung der Parameter einer elektrischen Maschine, welches sowohl die Eigenschaft hat, vollständig durchgeführt werden zu können – wie das Self-Commissioning-Verfahren – Kapitel 3.4.8 – – als auch eine nur teilweise Durchführung von Tests, wie z. B. nur Standstill-Identification – aus Kapitel 3.4.6 – oder die einzelne Tests aus dem Standstill-Identification-Verfahren, dem Gleichstromversuch – aus Kapitel 3.4.2 – und dem Kurzschlussversuch – aus Kapitel 3.4.4 –.

Der ID-Run verfügt über vier Optionen. Diese Optionen heißen: Normal, Reduced, Standstill und Advanced (ABB Group 2013, S. 305–306). Es wird empfohlen, nach Möglichkeit immer den normalen ID-Run zu wählen. Der normale ID-Run-Test wird bei vorwärts rotierendem Motor durchgeführt (ABB Group 2013, S. 305). Der Reduced-ID-Run wird durchgeführt, wenn

mechanische Verluste höher als 20% sind und somit der Motor nicht vom Inverter-System getrennt werden kann. Der Motor rotiert ebenfalls in Vorwärtsrichtung (ABB Group 2013, S. 306). Der Standstill-ID-Run wird bei stillstehendem Motor durchgeführt; der Motor wird mit DC-Signalen injiziert und aus der Reaktion werden die erforderlichen Maschinenparameter erfasst (ABB Group 2013, S. 306). Das ist das Verfahren, das auch in Kapitel 3.4.7 als Standstill-Identification behandelt wurde. Der Advanced-ID-Run wird durchgeführt, wenn die Maschinenparameter mit höchster Präzision erfasst werden müssen. Dabei läuft der Motor bei Höchstleistung und mit stark beschleunigtem Drehmoment (ABB Group 2013, S. 306). Der ID-Run bestimmt die Maschinenparameter und aktualisiert bzw. verfeinert auch die vom Nutzer eingegebenen Maschinendaten (ABB Group 2013, S. 301). Bestimmt werden der Statorwiderstand R_s, der Rotorwiderstand R_r, die Hauptinduktivität L_m, die Streuinduktivität L_σ, die d- und q-Achsen-Induktivitäten L_{d-q} sowie der Permanentmagnetfluss ψ_{PM} (ABB Group 2013, S. 301–302). Tabelle 10 gibt eine Übersicht über die Verfahren des ACS880 und deren entsprechende Methoden aus Kapitel 3.

Tabelle 10: Übersicht der ACS880-Verfahren und deren Zuordnung zu den in Kapitel 3 behandelten Methoden

ACS880-Verfahren	**Methoden/Verfahren aus Kapitel 3**
Normal ID-Run	3.4.5 Rampentest
Reduced ID-Run	3.4.5 Rampentest
Standstill ID-Run	3.4.6 Standstill-Identification
Advanced ID-Run	3.4.8 Self-Commissioning

4.4 Danfoss EC-C1200

Der Inverterhersteller Danfoss bietet für Industrie- und Mobilitätsanwendungen verschiedene Frequenzumrichterlösungen an (Danfoss Editron 2025a). Danfoss zählt zu den am häufigsten eingesetzten Inverter-Systemen in der Industrie (Salgarkar 2024; *Frequency inverter market* 2017). Diese Arbeit beschäftigt sich mit dem Modell EC-C1200. Der EC-C1200 kommt in verschiedenen Anwendungen zum Einsatz, unter anderem auch bei der Parametererfassung elektrischer Maschinen.

Für die Parametererfassung elektrischer Maschinen bietet der EC-C1200 mehrere Betriebsmodi, die eine vollständige Identifikation der Parameter vor der Inbetriebnahme ermöglichen. Eine Überwachung sowie dynamische Aktualisierung der Parameter während des Betriebs werden in den Dokumenten nicht erwähnt.

Jedoch gibt es beim EC-C1200 nicht die Option, eine vollautomatisierte Parametererfassung aller

Maschinenparameter in einem einzigen Ablauf durchzuführen, wie beim Self-Commissioning – aus Kapitel 4.2 – von SINAMICS oder Advanced ID-Run – aus Kapitel 4.3 – von ACS880. Für eine vollständige Parametererfassung müssen alle Betriebsmodi einzeln gestartet und durchgeführt werden. Je nach Bedarf an Maschinenparametern können entweder alle Modi oder einzelne davon ausgeführt werden (Danfoss Editron 2025b). Die folgenden Verfahren – Standstill, Free Rotating und Fixed Speed (Danfoss Editron 2025b) – werden im EC-C1200 zur Parametererfassung eingesetzt:

- Standstill: Durchführung bei stillstehendem Motor. Es werden DC-Signale injiziert und aus der Reaktion Parameter wie Statorwiderstand R_s und Induktivitäten L_σ ermittelt (Danfoss Editron 2025b). Entspricht inhaltlich dem in Kapitel 3.4.6 beschriebenen Standstill-Identification.
- Free Rotating: Durchführung bei mechanisch entkoppeltem, drehendem Motor. Zusätzliche Parameter wie Rotorinduktivitäten L_r (Danfoss Editron 2025b) werden ermittelt (Danfoss Editron 2025b).
- Fixed Speed: Durchführung bei externer Drehzahlsynchronisierung. Geeignet zur hochpräzisen Erfassung unter Lastbedingungen (Danfoss Editron 2025b).

Tabelle 11 gibt eine Übersicht über die Verfahren des EC-C1200 und deren entsprechende Methoden aus Kapitel 3.

Tabelle 11: Übersicht der EC-C1200-Verfahren und deren Zuordnung zu den in Kapitel 3 behandelten Methoden

EC-C1200-Verfahren	**Methoden/Verfahren aus Kapitel 3**
Standstill	3.4.6 Standstill-Identification
Free Rotating	3.4.5 Rampentest
Fixed Speed	3.4.5 Rampentest

Der EC-C1200 nutzt hauptsächlich Offline-Methoden zur Parametererfassung. Dabei werden die einzelnen Verfahren aus Kapitel 3 kombiniert, unter anderem Teile des Self-Commissioning – aus Kapitel 3.4.8 –, der Standstill-Identification – aus Kapitel 3.4.6 – und des Rampentests – aus Kapitel 3.4.5 –. In den Dokumenten zum EC-C1200 wird weder die Anwendung von Online-Verfahren noch eine darauf hinweisende Funktion erwähnt, sodass davon auszugehen ist, dass diese nicht Bestandteil der Software sind. Die Anwendung von adaptiven/intelligenten Verfahren wird nicht erwähnt, und es gibt auch keine Hinweise auf deren Einsatz.

Insgesamt stellt der EC-C1200 eine flexible und präzise Lösung für die teilautomatisierte Parametrierung elektrischer Maschinen dar.

4.5 Weitere Softwarelösungen

Neben den in den Kapiteln 4.2, 4.3 und 4.4 beschriebenen Softwarelösungen von Siemens SINAMICS, ABB ACS880 und Danfoss EC-C1200 bieten auch andere Hersteller entsprechende Inverter-Software, die der automatisierten oder zumindest teilautomatisierten Parametererfassung elektrischer Maschinen dient. Firmen wie Mitsubishi Electric, Rockwell Automation, Yaskawa, Schneider Electric und weitere haben Inverter-Softwarelösungen entwickelt, die in der Industrie ebenfalls eingesetzt werden (Fortune Business Insights 2025).

Diese Softwarelösungen haben in der Regel sehr ähnliche Funktionen und Parametererfassungsverfahren wie die, die in dieser Arbeit behandelt wurden. Alle beinhalten in der Regel Offline-Identifikationsverfahren wie Standstill-Identification – aus Kapitel 3.4.6 –, Rampentests – aus Kapitel 3.4.5 – sowie, je nach Hersteller, eine vollautomatisierte Parametrierung wie das Self-Commissioning-Verfahren – aus Kapitel 3.4.8 – oder eine teilautomatisierte Parametrierung wie bei der Inverter-Software von Danfoss EC-C1200 – aus Kapitel 4.4 –. Unterschiede bestehen vor allem in der Benutzeroberfläche, der Präzision der Parametererfassung, den verwendeten Online-Verfahren oder in herstellerspezifischen Zusatzfunktionen.

Die drei Softwarelösungen, die in dieser Arbeit behandelt wurden, sind die in der Industrie am weitesten verbreiteten Inverter-Softwarelösungen. Aus diesem Grund wurde der Fokus auf diese gelegt. Inverter-Softwarelösungen von anderen Herstellern sind, wie oben beschrieben, weitgehend vergleichbar und würden daher keine zusätzlichen Erkenntnisse für das Thema dieser Arbeit liefern.

4.6 Vergleich der Softwarelösungen und Fazit

Die drei in dieser Arbeit behandelten Inverter-Softwarelösungen – Siemens SINAMICS, ABB ACS880 und Danfoss EC-C1200 – unterscheiden sich hauptsächlich in der Art und Kombination der zur Parametererfassung eingesetzten Verfahren.

- Siemens SINAMICS: Bietet eine vollautomatisierte Erfassung aller relevanten Maschinenparameter in einem einzigen Testlauf. Dabei werden hauptsächlich Offline-Methoden wie Self-Commissioning – Kapitel 3.4.8 –, Standstill-Identification – Kapitel 3.4.6 – und Rampentest – Kapitel 3.4.5 – eingesetzt. Online-Methoden werden zur Überwachung der Maschinenparameter verwendet. Die Verfahren können auch einzeln durchgeführt werden, je nach Bedarf an Maschinenparametern.

- ABB ACS880: Bietet mehrere automatisierte Verfahren an, bei denen je nach Bedarf und Präzision ein geeigneter Modus ausgewählt werden kann. Das Verfahren heißt ID-Run – Kapitel 4.3 – und bietet vier Varianten. Normal-ID-Run und Reduced-ID-Run basieren auf rotierenden Tests – ähnlich Rampentest, Kapitel 3.4.6 –, Standstill-ID-Run entspricht der

Standstill-Identification – Kapitel 3.4.6 –, und Advanced-ID-Run – Kapitel 4.3 – integriert alle Schritte zu einer vollständigen Parametrierung, genau wie bei Self-Commissioning in Kapitel 3.4.8 bzw. in SINAMICS – Kapitel 4.2 –.

- Danfoss EC-C1200: Bietet drei separate Verfahren an, die nicht miteinander verknüpft werden können, d. h. die Verfahren können nur einzeln durchgeführt werden. Standstill, Free Rotating und Fixed Speed – Kapitel 4.4 –. Free Rotating erlaubt Messungen bei entkoppeltem, freilaufendem Motor. Fixed Speed ermöglicht präzise Messungen bei externer Drehzahlsynchronisation. Standstill entspricht der Standstill-Identification aus Kapitel 3.4.6. Eine vollständige automatisierte Parametrierung in einem Lauf ist nicht möglich.

Die erfassten Maschinenparameter sind bei allen Verfahren gleich, jedoch unterscheiden sich Präzision, Kombination und Implementierung der eingesetzten Verfahren.

Aus der Gegenüberstellung wird deutlich, dass:

- SINAMICS den höchsten Automatisierungsgrad bietet und alle relevanten Methoden in einem automatisierten Verfahren kombiniert,
- ACS880 mit seinen vier ID-Run-Varianten eine hohe Flexibilität bei gleichzeitig möglicher Vollautomatisierung bietet,
- EC-C1200 auf klar voneinander getrennte Einzelverfahren setzt, die der Anwender gezielt auswählen und nacheinander ausführen muss.

Für Anwendungen, in denen die Erfassung aller Maschinenparameter schnell und vollständig in einem Ablauf erfasst werden müssen, sind Systeme wie SINAMICS oder der Advanced ID-Run des ACS880 im Vorteil. Wenn bestimmte Parameter unter klar definierten Betriebsbedingungen separat erfasst werden sollen, ist der EC-C1200 von Vorteil.

Die Unterschiede sind weniger in den erfassten Größen, sondern vielmehr in der Integration der Parametererfassungsmethoden. Daher sollte bei der Auswahl eines geeigneten Inverter-Softwarelösung nicht auf die Maschinenparameter selbst, sondern auf die erforderliche Flexibilität, Aufwand und Präzision geachtet werden. Tabelle 12 bietet dabei eine Übersicht über die wichtigsten Unterscheidungsmerkmale der Verfahren.

Tabelle 12: Vergleich der Softwarelösungen hinsichtlich Automatisierungsgrad, Flexibilität, Kombinationsmöglichkeiten und Online-Funktionen

Softwarelösung	**Grad der Automatisierung**	**Flexibilität**	**Kombination der Verfahren möglich**	**Vorhandene Online-Verfahren**
Siemens SINAMICS	Vollautomatisch (alle relevanten Methoden in einem Lauf)	Ja, auch Einzeldurchführung möglich	Ja	Ja (zur Überwachung der Maschinenparameter)
ABB ACS880	Vollautomatisch oder teilautomatisch (je nach ID-Run-Variante)	Ja (4 Varianten: Normal, Reduced, Standstill, Advanced)	Ja (4 Varianten: Normal, Reduced, Standstill, Advanced)	Ja (abhängig vom gewählten Modus)
Danfoss EC-C1200	Nur Einzelschritte, keine Gesamtautomatisierung	Ja (3 getrennte Verfahren: Standstill, Free Rotating, Fixed Speed)	Nein	Nein

5 Zukunftsperspektiven zur Inverter-Software und Parametererfassung

In diesem Kapitel werden neue, experimentelle Methoden zur Parametererfassung elektrischer Maschinen vorgestellt. Diese Methoden werden vor allem in der Forschung und bei Experimenten eingesetzt. Ziel ist es, deren Funktionsprinzip zu untersuchen. Danach werden potenzielle neue Softwarelösungen bzw. neue Produkte zur Parametererfassung elektrischer Maschinen untersucht. Im Anschluss werden sie mit den bereits bekannten Methoden aus Kapitel 3 verglichen.

5.1 Potenzielle Methoden zur Parametererfassung

5.1.1 Recursive Prediction Error Method (RPEM)

Die Recursive Prediction Error Method (RPEM) ist ein fortschrittliches, experimentelles Online-Verfahren zur Parametererfassung elektrischer Maschinen. Die Maschinenparameter, die sich durch Temperaturänderungen oder Sättigungseffekte ändern, werden hierbei adaptiv geschätzt (Perera und Nilsen 2022, S. 1). Dabei werden wichtige Maschinenparameter wie der Statorwiderstand R_s, der Permanentmagnetfluss Ψ_{PM} sowie die d- und q-Achsen-Induktivitäten L_{d-q} bestimmt (Perera und Nilsen 2022, S. 1–2). Der Vorhersagefehler zwischen gemessenen Signalen und den modellierten Signalen der Maschine wird minimiert (Perera und Nilsen 2022, S. 2).

Es handelt sich um eine verbesserte bzw. fortgeschrittene Version des klassischen Verfahrens Recursive Least Squares (RLS) – siehe Kapitel 3.5.2.6 Bei RPEM wird, im Gegensatz zu RLS, der Gradient der Vorhersagegleichung verwendet, um die Schätzwerte iterativ anzupassen. Dies ermöglicht eine schnellere Konvergenz und eine höhere Robustheit gegenüber Messrauschen (Perera und Nilsen 2022, S. 2).

Die Formeln 22, 23 und 24 zeigen, dass RPEM – im Unterschied zu RLS, das den Fehler über die Regressor-Matrix φ minimiert – den Gradienten der Vorhersagegleichung Ψ^T nutzt. Damit werden die Schätzwerte iterativ angepasst. Dadurch wird das Verfahren robuster, da keine Matrixinversionen wie beim RLS erforderlich sind.

$$\hat{\theta}[k] = \hat{\theta}[k-1] + L[k] \cdot \varepsilon_s[k] \tag{22}$$

$$L[k] = \gamma[k]\frac{1}{r[k]}\Psi[k] \tag{23}$$

$$r[k] = r[k-1] + \gamma[k]\left(\mathrm{tr}\left\{\Psi[k]\cdot\Psi^T[k]\right\} - r[k-1]\right) \tag{24}$$

(Perera und Nilsen 2022, S. 7)

Die Parameter werden durch sukzessive Anpassung eines Schätzvektors $\hat{\theta}(k)$ aktualisiert (Perera und Nilsen 2022, S. 2–5). Ein Gain-Vektor wird aus der Sensitivität des Modells gegenüber den Parametern berechnet. Dieser iterative Prozess wird in Echtzeit durchgeführt (Perera und Nilsen 2022, S. 2–4). Diese Methode wurde in der Forschung und auf Embedded-Real-Time-Plattformen mit Erfolg getestet (Perera und Nilsen 2022, S. 1–3).

5.1.2 MRAS mit Active Disturbance Rejection Control)

Der MRAS mit Active Disturbance Rejection Control – ADRC – basiert auf dem klassischen MRAS aus Kapitel 3.5.2.3 Die Anpassungslogik wird hierbei erweitert durch eine Active-Disturbance-Rejection-Regelung – ADRC – mit variabler Bandbreite (Qi u. a. 2023, S. 5–6). Dadurch wird das entstehende Messrauschen unterdrückt und nicht modellierte Störungen werden kompensiert, während des Identifikationsprozesses (Qi u. a. 2023, S. 12).

Das klassische MRAS kompensiert den Anpassungsfehler mit einem PI-Regler (Qi u. a. 2023, S. 5–7). Die ADRC-Struktur hingegen verfügt über einen erweiterten Zustandsbeobachter – ESO – (Qi u. a. 2023, S. 5). Dieser Zustandsbeobachter schätzt die Störungen in Echtzeit und kompensiert sie. Die Bandbreite des ESO wird adaptiv an die Betriebsbedingungen angepasst. Dadurch werden die Konvergenzgeschwindigkeit und die Genauigkeit gesteigert (Qi u. a. 2023, S. 5–8).

Abbildung 25 zeigt den Aufbau des ADRC. Der ESO im ADRC schätzt die unbekannten Störungen z_2 sowie den Systemzustand z_1 und kompensiert diese.

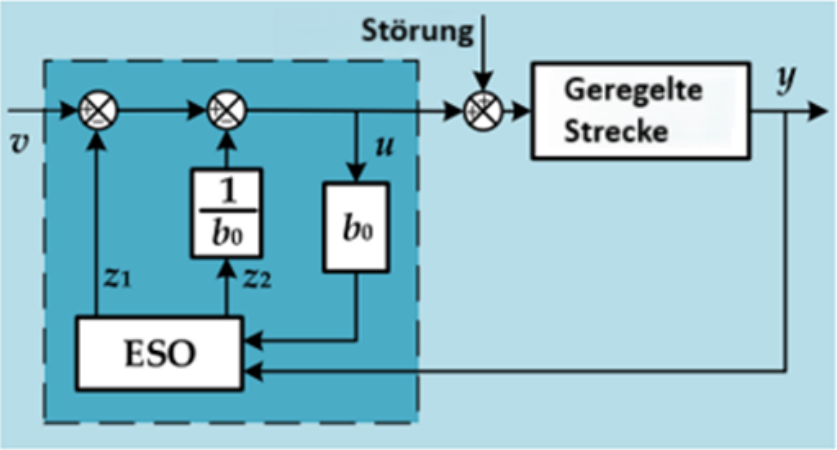

Abbildung 25: Struktur des Active Disturbance Rejection Control (ADRC) mit Extended State Observer (ESO)(Qi u. a. 2023, S. 5)

Experimentelle Ergebnisse an einer elektrischen Maschine zeigen, dass MRAS + ADRC den Statorwiderstand R_s, die Achseninduktivitäten $L_{d\text{-}q}$ sowie den Permanentmagnetfluss Ψ_{PM} auch unter starkem Rauschen zuverlässig erfassen kann (Qi u. a. 2023, S. 9–12). Der Rechenaufwand ist dabei moderat. Aus diesem Grund ist die Implementierung auf Embedded-Plattformen möglich (Qi u. a. 2023, S. 2). MRAS + ADRC könnte das klassische MRAS ersetzen, wenn präzise Maschinenparameter unter stark änderlichen und verzerrten Bedingungen erfasst werden müssen, ohne den Rechenaufwand und die Komplexität zu erhöhen.

5.1.3 Physics-Informed Neural Networks

Physics-Informed Neural Networks stellen eine Erweiterung der in Kapitel 3.6.6 beschriebenen neuronalen Netze dar. Sie kombinieren die neuronalen Netze aus adaptiven/intelligenten Methoden – Kapitel 3.6 – mit Observer-gestützten-Verfahren – Kapitel 3.5.2 – aus Online-Methoden. Anders als bei neuronalen Netzen werden bei PINNs neben den Datensätzen und Trainingsdaten auch die mathematischen Modelle der elektrischen Maschine betrachtet. Im Grunde werden die Differentialgleichungen des Maschinenmodells in den Trainingsprozess integriert (Farkane u. a. 2025, S. 2).

Aus diesem Grund bestehen PINNs nicht nur aus einem datenbasierten Teil, der aus Messgrößen abgeleitet wird, sondern gleichzeitig aus einer physikbasierten Verlustfunktion (Farkane u. a. 2025, S. 23). Dadurch können die geschätzten Parameter die physikalischen Gesetzmäßigkeiten erfüllen.

Der erste Teil des Verfahrens ist klassisch, d. h. das Modell erhält wie immer die gleichen Eingangssignale wie die reale Maschine. Es vergleicht seine Ausgänge mit den gemessenen Größen und passt die internen Parameter wie Stator- und Rotorwiderstand R_s, R_r, Induktivitäten L, Momente J und Polpaarzahl p entsprechend an (Farkane u. a. 2025, S. 7–10). Zustandsparameter

wie Rotorfluss Ψ_r und Winkelgeschwindigkeit ω werden ebenfalls erfasst (Farkane u. a. 2025, S. 25–28). Zusätzlich kommt hier ein „physikalischer Fehler“ ins Spiel (Farkane u. a. 2025, S. 25). Die Fehler aus den Signalen und aus dem Modell werden mit dem mathematischen Fehler kombiniert und dementsprechend kompensiert. Das führt zu einer robusteren und präziseren Parametererfassung der elektrischen Maschine (Farkane u. a. 2025, S. 31).

Abbildung 26 zeigt den Aufbau eines PINNs zur Zustands- und Parameterbeobachtung. Im Gegensatz zu klassischen neuronalen Netzen – aus Kapitel 3.6.6 –, die nur auf Trainingsdaten basieren, nutzt das PINN zusätzlich die physikalischen Gleichungen des Systems. Für die Parametererfassung elektrischer Maschinen durch Inverter bedeutet das, dass PINNs nicht nur Messdaten $y(t)$ und Eingangssignale $u(t)$ auswerten, sondern auch das Maschinenmodell berücksichtigen. Dadurch können die Parameter robuster und mit weniger Datenaufwand bestimmt werden.

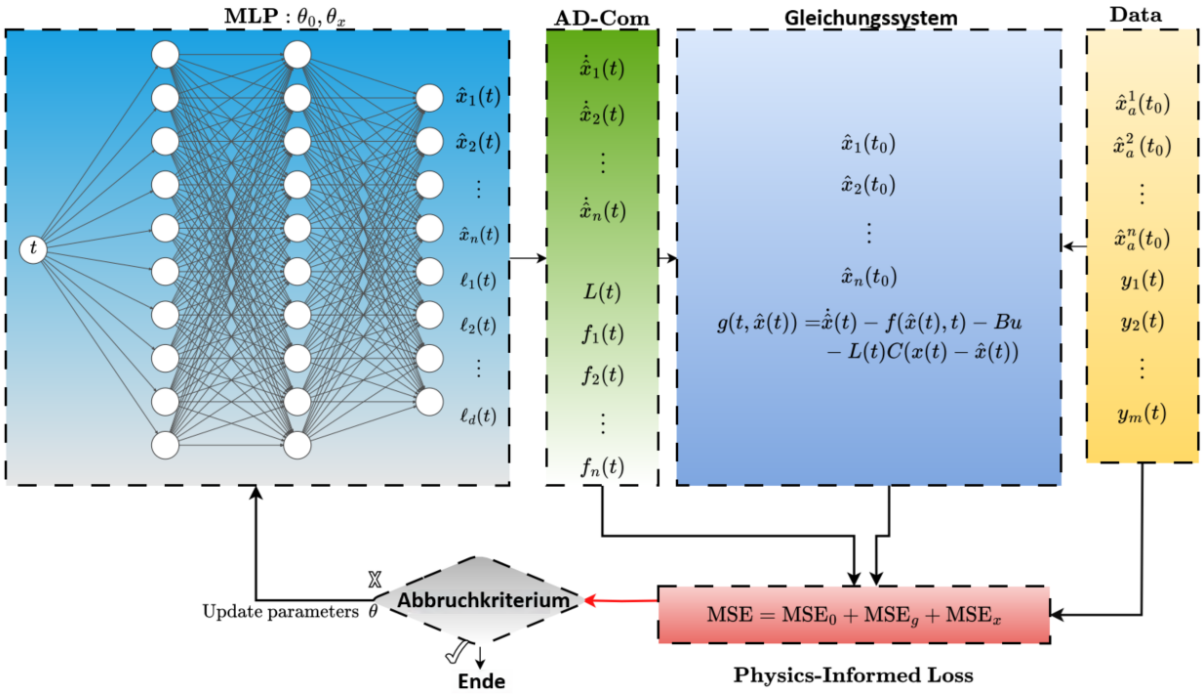

Abbildung 26: Aufbau eines Physics-Informed Neural Networks (PINN) zur Zustands- und Parameterbeobachtung elektrischer Maschinen (Farkane u. a. 2025, S. 8)

Eine experimentelle Arbeit zeigt, dass PINN-gestützte Online-Observer mehrere Maschinenparameter in Echtzeit bestimmen können (Farkane u. a. 2025, S. 19). Da dieses Verfahren aus zwei kombinierten Verfahren besteht, kann auch bei unvollständigen Datensätzen oder sich stark ändernden Betriebsbedingungen Parameter erfasst werden. Das Prinzip ist einfach: Wenn der eine fehlt oder unvollständig ist, hilft der andere. Der Rechenaufwand ist hoch, aufgrund der Kombination von zwei aufwändigen Verfahren. Es könnte in Embedded-Systeme integriert werden, jedoch muss das System eine hohe Leistung haben.

Diese Methode könnte in Zukunft die klassischen neuronalen Netze und Observer-Gestützten-

Methoden ersetzen, wenn sowohl eine hohe Genauigkeit als auch physikalische Konsistenz der Parameter wichtig sind.

5.1.4 Chirp-Signal-Identification

Die Chirp-Signal-Identification ist ein experimentelles Offline-Verfahren zur Parametererfassung elektrischer Maschinen im Stillstand. Der klassische Standstill-Identification aus Kapitel 3.4.6 speist einzelne feste Prüfspannungen ein. Bei der Chirp-Signal-Identification hingegen wird ein kontinuierlich steigendes bzw. abfallendes Frequenzsignal in die Statorwicklungen eingespeist (Cisneros-González u. a. 2013, S. 45). Das sorgt dafür, dass in einem einzigen Durchgang ein breites Frequenzspektrum abgedeckt wird. Dies ermöglicht die Erfassung statischer und frequenzabhängiger Maschinenparameter (Cisneros-González u. a. 2013, S. 47).

Erfasst werden dabei nicht nur die grundlegenden Maschinenparameter wie der Statorwiderstand R_s, die d- und q-Achsen-Induktivitäten $L_{d\text{-}q}$, sondern durch das erweiterte Modell auch noch feldrelevante Parameter, Dämpferwicklungen i_k und Dämpferwicklungsreaktanzen X_k (Cisneros-González u. a. 2013, S. 48). Dadurch kombiniert das Verfahren mehrere Einzeltests in einem breiten Frequenzspektrum; statt mehrere Tests automatisiert in einem Lauf durchzuführen, führt es nur einen Test durch, der alle erforderlichen Parameter dadurch erfassen kann.

Der Inverter speist das Chirp-Signal – kontinuierlich steigende bzw. fallende Frequenz – bei blockiertem Rotor ein, erfasst die Stromantworten und aus der Verarbeitung dieser Antworten – geeignete Anpassungs- oder Filterverfahren – werden die Maschinenparameter bestimmt. Einige Experimente zeigen, dass diese Methode eine hohe Genauigkeit bei kurzer Messdauer bietet (Cisneros-González u. a. 2013, S. 50). Durch die breitbandige Anregung können zudem Parameter erfasst werden, die bei niedriger oder hoher Frequenz stark abweichen.

Die Chirp-Signal-Identification wird in kommerziellen Inverter-Software noch nicht eingesetzt, bietet aber ein hohes Potenzial für die Zukunft der Offline-Verfahren, aufgrund der einfachen Durchführung im Stillstand und der umfassenden Parameterauswertung. Sie könnte als Alternative zu Self-Commissioning-Verfahren eingesetzt werden oder als Ergänzung.

5.1.5 Vergleich der potenziellen Methoden und Fazit

Die in Tabelle 13 dargestellten experimentellen Verfahren zur Parametererfassung elektrischer Maschinen zeigen deutlich die Entwicklungstendenzen zukünftiger Ansätze. Während heute mit einzelnen oder automatisierten Offline-Tests wichtige Maschinenparameter erfasst werden, nur mit ergänzender Unterstützung durch Online-Methoden, bieten experimentelle und potenziell neue Methoden eine viel flexiblere, präzisere und auf Online-Methoden sowie adaptive/intelligente Lösungen basierende Verfahren. Dabei werden die Methoden oft kombiniert. Auffällig ist dabei, dass der Fokus verstärkt auf eine höhere Robustheit gegenüber Störgrößen,

verkürzte Messzeiten sowie eine automatisierte Durchführung innerhalb des Inverters gelegt wird.

Tabelle 13: Vergleich der Methoden zur Parametererfassung

Kriterium / Methode	**RPEM**	**MRAS mit ADRC**	**Physics-Informed Neural Networks**	**Chirp-Signal-Identification**
Messaufwand	Mittel	Mittel	Gering–mittel	Gering
Rechenaufwand	Mittel–hoch	Mittel–hoch	Hoch	Mittel
Genauigkeit	Hoch	Sehr hoch	Sehr hoch	Hoch
Modell erforderlich	Ja	Ja	Ja	Ja
Robustheit	Robust gegen Rauschen	Sehr hoch	Robust gegen Temperatur-effekten und Sättigung	Hoch
Flexibilität	Hoch	Hoch	Sehr hoch	Mittel
Basiert auf	RLS	MRAS	Neuronale Netze	Standstill-Identification
Neu/Erweiterung	Gradient zur Anpassung	ADRC + ESO	Observer	Chirp-Signal
Erfasste Parameter	$R_s, \Psi_{PM}, L_{d\text{-}q}$	$R_s, \Psi_{PM}, L_{d\text{-}q}$	$R_s, R_r, L, J, p, \Psi_r, \omega$	$R_s, L_{d\text{-}q}, i_k, X_k$

Ein weiterer Unterschied besteht in der Flexibilität. Die experimentellen Methoden basieren zwar auf klassischen Offline-, Online- oder adaptiv/intelligente Methoden, erweitern diese jedoch. Zum Beispiel werden sie durch Chirp-Erweiterung, ADRC, PINNs oder RPEM erweitert.

Hinsichtlich der erfassten Parameter bieten die Methoden deutliche Unterschiede:

- Die Chirp-Signal-Identification ermöglicht die Parametererfassung im Stillstand. Wichtig ist dabei, dass ein breitbandiges Frequenzsignal dafür sorgt, dass Maschinenparameter aus einem sehr breiten Umfeld erfasst werden können. Darunter auch d/q-Achsen-Induktivitäten $L_{d\text{-}q}$, feldrelevante Größen und Dämpferparameter.
- MRAS mit ADRC konzentriert sich stärker auf die Parameter wie Statorwiderstand R_s, die Achseninduktivitäten $L_{d\text{-}q}$ und Permanentmagnetfluss Ψ_{PM}. Es bietet eine robuste Anpassung bei variablen Maschinenbedingungen.
- Die RPEM-Methode passt die Schätzwerte iterativ über einen Gradienten der Vorhersagegleichung an. Dies führt zu einer besseren Robustheit, jedoch auch zu erhöhtem

Rechenaufwand. Erfasst werden dabei Statorwiderstand R_s, Permanentmagnetfluss Ψ_{PM} sowie d- und q-Achsen-Induktivitäten $L_{d\text{-}q}$.

- PINN-Verfahren liefern eine besonders hohe Flexibilität und Modellgenauigkeit. Erfasst werden dabei Stator- und Rotorwiderstand R_s, R_r, Induktivitäten L, Momente J und Polpaarzahl p, Rotorfluss Ψ_r sowie Winkelgeschwindigkeit ω_r.
- Die Chirp-Signal-Identification ist unter diesen experimentellen Methoden die praxisnaheste Methode. Sie ist eine potenzielle Erweiterung für die Standstill-Identification im Self-Commissioning-Prozess. Die Implementierung in den aktuellen Inverter-Systemen ist einfach, da es mit einer Softwareänderung und gegebenenfalls leichten Hardwareänderungen möglich wäre.
- Die RPEM-Methode ist eine starke potenzielle Alternative für die jetzigen Online-Methoden. Aufgrund ihres hohen Rechenaufwands jedoch heute nur für Forschungsumgebungen und Experimente geeignet. KI-gestützte Verfahren wie PINNs bieten eine präzise und robuste Lösung zur Erfassung der Maschinenparameter, sind jedoch sehr rechenaufwendig aufgrund der Kombination von neuronalen Netzen und Observatoren. Mit sehr starker Hardware der Inverter ist es eine gute Alternative, jedoch immer noch nur in Forschungsumgebungen anwendbar.
- MRAS + ADRC bietet eine sehr hohe Genauigkeit sowie mittleren Rechenaufwand. Es ist ein starker Kandidat, um das klassische Online-Verfahren MRAS in der Zukunft zu ersetzen.

Zusammenfassend lässt sich feststellen, dass die experimentellen Verfahren die klassischen Methoden nicht direkt ersetzen, sondern mit zusätzlichen Funktionen die klassischen Verfahren verbessern, insbesondere hinsichtlich des Rauschens. Dabei werden die Messzeiten auch verkürzt.

Das größte Problem derzeit ist die Implementierung dieser Methoden, weil die aktuellen Inverter-Lösungen auf dem Markt weder den sehr hohen Rechenaufwand mancher Methoden verarbeiten können noch die Integration in die Software erfolgt ist. Dies kann durch stärkere Inverterhardware oder eigene Embedded-Systeme gelöst werden. Alternativ können die experimentellen Methoden noch weiter optimiert und der Rechenaufwand verringert werden.

5.2 Potenzielle Softwarelösungen

In diesem Kapitel werden die Softwarelösungen aus der Industrie behandelt, die in Zukunft in die Inverter-Software integriert werden könnten. Es geht um Softwarelösungen, die bereits für andere Funktionen eingesetzt werden und Potenzial als Zusatzfunktion für die Parametererfassung elektrischer Maschinen haben.

5.2.1 Cloud-Lösungen

Die Cloud-Anwendungen sind für die Parametererfassung elektrischer Maschinen relevant, da in der Cloud sehr große Datenmengen an Maschinenparameter von unterschiedlichen Maschinen in unterschiedlichen Betriebszuständen gesammelt werden. Zum Beispiel ändern sich die Maschinenparameter wie Rotorwiderstand R_r oder Rotorzeitkonstante T_r durch Temperatur, Alterung oder Lastprofile. Die Softwarelösungen aus Kapitel 4 arbeiten meistens offline und lokal, weshalb sie auf dynamische Veränderungen nicht reagieren bzw. sich anpassen können. Integrierte Cloud-Lösungen in Inverter-Software hingegen ermöglichen den Vergleich innerhalb einer Flotte. Das heißt, Abweichungen eines Motors können mit tausenden ähnlichen Maschinen verglichen werden. Daraus lassen sich die Maschinenparameter annähern und optimieren. Alterungseffekte werden dadurch sichtbar, sodass Parameter kontinuierlich korrigiert werden können. Da Cloud-Systeme reich an Daten sind, können KI-Modelle viel einfacher integriert werden, auch die intelligenten Methoden aus Kapitel 3.6. Die folgenden Inverter-Hersteller bieten aktuell auch Cloud-Lösungen an, die zwar nicht direkt in Inverter-Software integriert sind und nicht für die Parameterbestimmung entwickelt wurden, jedoch potenziell in die Inverter-Software integrierbar und somit auch relevant für die Parametererfassung:

- Siemens: Siemens bietet verschiedene Anwendungen im Bereich Cloud-Services an. Darunter zählen Anwendungen wie *Analyze MyDrives Cloud*, *Sidrive IQ* und *Insights Hub*. Diese Anwendungen sammeln Motordaten aus elektrischen Maschinen, analysieren und visualisieren sie. Der Fokus liegt dabei auf Monitoring, Diagnose und Wartungsoptimierung (Siemens AG 2021, S. 9; Siemens AG 2023, S. 23; Siemens AG 2025c, S. 1–4).
- ABB: ABB bietet „ABB Ability Condition Monitoring for Drives“ und die „Digital Powertrain Plattform“. Beide sind cloudbasierte Services für elektrische Maschinen. Dabei werden Motordaten gesammelt und in der Cloud gespeichert, sowie mit anderen Motordaten verglichen (ABB Group 2024, S. 1–5; ABB Group 2020).
- Schneider Electric: Schneider Electric bietet die *EcoStruxure Machine Advisor*. Es handelt sich um ein Cloud-System, in dem sich viele Maschinenparameter speichern lassen (Schneider Electric 2019, S. 4–8).

Zusammenfassend lässt sich feststellen, dass Cloud-Lösungen für die Online- und adaptiv/intelligenten Methoden der Parametererfassung einer elektrischen Maschine nützlich sind. Die gespeicherten Maschinendaten aus vielen unterschiedlichen Maschinen lassen sich vergleichen, bilden eine Basis für die Weiterverwendung bei intelligenten Methoden und dienen zur Überwachung einer elektrischen Maschine.

5.2.2 Edge-Lösungen

Die Edge-Anwendungen sind für die Parametererfassung elektrischer Maschinen relevant, da Daten direkt am Ort der Maschine oder im Inverter verarbeitet werden. Parameter wie Stator- und Rotorwiderstand oder Induktivitäten können in Echtzeit überwacht und angepasst werden. Edge-Anwendungen bearbeiten die Parameter lokal und damit auch schneller als Cloud-Systemen.

Edge-Systeme können in die Inverter-Software integriert werden. Sie bilden eine Brücke zwischen Maschinenparameter und Cloud-Systeme, indem sie die lokale Verarbeitung von kurzfristigen Maschinenparametern ermöglichen und auf der anderen Seite die langfristigen Maschinenparameter aus Cloud-Systemen beziehen.

Ein weiterer Vorteil von Edge-Systemen ist die Möglichkeit, zusätzliche Software-Apps sowie KI-Algorithmen zu kombinieren. Dadurch können Maschinenparameter auf verschiedene Weisen erfasst und verarbeitet werden, je nach Algorithmus. Die folgenden Inverter-Hersteller bieten aktuell Edge-Lösungen an, die primär für Monitoring, Diagnose und Optimierung entwickelt wurden, jedoch potenziell auch für die kontinuierliche Parametererfassung elektrischer Maschinen genutzt werden zu können:

- Siemens: Siemens verfügt über die *Industrial Edge Plattform*. Apps können direkt am Inverter oder in der Automatisierungsumgebung ausgeführt werden. Dabei liegt der Fokus auf Echtzeitdatenverarbeitung, Analyse und Erweiterbarkeit (Siemens AG 2025d; Siemens AG 2025b).
- Rockwell Automation: Rockwell bietet das *FactoryTalk Edge Gateway*. Dabei werden Antriebsdaten lokal verarbeitet (Rockwell Automation 2025, S. 2–5).
- Yaskawa: Yaskawa hat die Funktion *Yaskawa Cockpit*, die die Antriebsdaten in Echtzeit sammelt und verarbeitet (Yaskawa America INC. 2021).

Zusammenfassend lässt sich feststellen, dass Edge-Lösungen eine Brücke zwischen allen Methoden aus Kapitel 3, bzw. Algorithmen und Cloud-Systemen bilden. Sie bieten die Möglichkeit, in Edge-Schnittstellen Algorithmen oder Parametererfassungsmethoden zu integrieren und die Daten aus Cloud-Systemen zu beziehen, was eine lokale und schnelle Verarbeitung globaler Maschinendaten ermöglicht.

6 Schluss: Erkenntnisse und Ausblick

6.1 Zusammenfassung der Ergebnisse

In dieser Arbeit wurden die wichtigsten Parameter einer elektrischen Maschine festgestellt und die wichtigsten klassischen Methoden zur Parametererfassung einer elektrischen Maschine systematisch dargestellt, analysiert und miteinander verglichen. Die Betrachtung zeigte, dass sich die Methoden in drei Hauptgruppen einteilen lassen: Offline-, Online- sowie adaptive bzw. intelligente Verfahren. Dabei wurde festgestellt, welche Methode unter welchen Bedingungen und Anforderungen bevorzugt werden muss und welche Maschinenparameter durch diese Methoden bestimmt werden können. Außerdem wurden aktuelle industrielle Inverter-Softwarelösungen zur Parametererfassung analysiert und den klassischen Methoden gegenübergestellt, dabei wurde untersucht, welche klassischen Methoden aktuell in industrieller Inverter-Software eingesetzt werden. Anschließend wurden potenzielle neue Methoden zur Parametererfassung analysiert, beschrieben und verglichen. Zum Schluss wurden potenzielle neue Softwarefunktionen aus der Industrie beschrieben, die in Zukunft auch für die Parametererfassung eingesetzt werden könnten.

Die Analyse der Offline-Methoden und aktuellen Inverter-Software verdeutlichte, dass Offline-Verfahren für die Parametrierung vor der Inbetriebnahme unverzichtbar sind. Sie sind die Hauptfunktion heutiger Inverter-Software und bilden die Grundlage. Sie werden meistens automatisiert durchgeführt. Jedoch werden die Parameter dabei nur als Momentaufnahme erfasst. Veränderungen durch Temperatur, Sättigung oder Alterung können nicht berücksichtigt werden.

Die Online-Methoden hingegen ermöglichen eine kontinuierliche Erfassung der Parameter. Sie bestehen entweder aus injektionsbasierten Methoden, bei denen bei niedrigen Drehzahlen kontinuierliche Stromimpulse in den Motor injiziert werden und anhand der Stromantwort die Parameter erfasst bzw. angepasst werden, oder aus Observer-gestützten Verfahren, bei denen bei mittleren bis hohen Drehzahlen aus erzeugten mathematischen Maschinenmodellen und Algorithmen die Maschinenparameter bestimmt werden. Online-Methoden werden in aktuellen industriellen Inverter-Software implizit eingesetzt. Die automatisierten Offline-Methoden in industriellen Inverter-Software haben auch für die kontinuierliche Anpassung der Parameter integrierte Online-Methoden, meist in Form von Observern und ergänzend zu den Offline-Methoden.

Die adaptiven/intelligenten Methoden sind besonders von Vorteil, wenn kein Maschinenmodell vorliegt, sehr viele nichtlineare Zusammenhänge vorliegen und Trainingsdaten verfügbar sind. Sie sind sehr robust gegen Unsicherheiten und Störungen. Sie passen sich an veränderliche

Betriebsbedingungen schnell an. Jedoch erfordern sie große Mengen an präzisen Trainingsdaten. Sie kommen in industriellen Inverter-Software nicht vor und werden in experimentellen Umgebungen durchgeführt, vor allem in der Forschung.

Die Untersuchung der aktuellen Inverter-Softwarelösungen zeigte, dass diese heute überwiegend auf automatisierte Offline-Verfahren beruhen. Die am häufigsten vorkommenden Softwaresysteme haben alle entweder vollautomatisierte oder teils automatisierte offline Parametererfassungsverfahren vor der Inbetriebnahme. Außerdem verfügen sie über ergänzende Online-Methoden, die nicht explizit erwähnt werden aber aus den Dokumenten der Inverterhersteller hergeleitet werden können.

Bei den potenziellen neuen Methoden wurde deutlich, dass die Forschung verstärkt in Richtung online oder adaptive/intelligente Verfahren geht. Diese Methoden bauen auf den bereits bestehenden Online- oder adaptiven/intelligenten Methoden auf und werden weiterentwickelt.

Die Betrachtung von Cloud- und Edge-Lösungen als potenzielle Parametererfassungsmethode zeigte, dass diese Systeme eine Brücke zwischen den klassischen Methoden und modernen datengetriebenen Ansätzen bilden können. Cloud-Systeme speichern große Mengen an Maschinendaten aus zahlreichen Maschinen, können diese vergleichen und langfristige Effekte wie z.B. Alterungseffekte erkennen. Edge Systeme bieten die Möglichkeit, in Echtzeit und direkt am Inverter zu arbeiten. Sie können in Echtzeit Apps, Algorithmen und ähnliche in den Inverter integrieren. Somit könnten beide Lösungen in Zukunft auch für die Parametererfassung elektrischer Maschinen eingesetzt werden.

Insgesamt lässt sich festhalten, dass die aktuellen Inverter-Software zwar sichere Maschinenparameter liefern, jedoch überwiegend mit der Anwendung von offline Methoden und vor der Inbetriebnahme. Es bestehen viele online und adaptive/intelligente Methoden zur Verfügung, die in der Forschung experimentell weiterentwickelt werden. Außerdem haben aktuelle Inverter-Hersteller auch andere Funktionen zu bieten, die hauptsächlich für andere Aufgaben entwickelt worden sind, jedoch das Potenzial haben, auch für die Parametererfassung elektrischer Maschinen eigesetzt zu werden.

6.2 Ausblick und Handlungsempfehlungen

Die Entwicklung in der Parametererfassung elektrischer Maschinen durch Inverter-Software wird in den kommenden Jahren stark geprägt sein, durch die zunehmende Integration von datengetriebenen und intelligenten Methoden. Die Kombination von bereits häufig angewendeten klassischen Offline-Verfahren mit Online- oder adaptiven/intelligenten Verfahren stellt besonders einen wichtigen Schritt dar. Dabei wird sowohl eine zuverlässige Parametrierung als auch eine kontinuierliche Anpassung der Parameter im Betrieb gewährleistet.

Bei den einzelnen Methoden ist der Trend so, dass besonders Online- und adaptive/intelligente Verfahren weiterentwickelt werden. Dabei werden sie zusätzlich mit Observern, neuen Algorithmen und Gradienten unterstützt bzw. erweitert. Auf der anderen Seite werden auch Offline-Verfahren weiterentwickelt, jedoch liegt der Schwerpunkt bei den Online- und adaptiven/intelligenten Verfahren.

Bei den industriellen Inverterherstellern ist ein wesentlicher Trend die Verknüpfung von Cloud- und Edge-Technologien mit Inverter-Software. Während Edge-Systeme die lokale Echtzeitfähigkeit sichern und eine Schnittstelle erzeugen, in der Apps und neue Algorithmen, unter anderem auch die modernen Ansätze, installiert werden können, bieten Cloud-Systeme die Möglichkeit, globale Daten zu nutzen und durch Flottenvergleiche sowie KI-Modelle Parameter zu validieren und zu optimieren. Hersteller werden daher zunehmend hybride Architekturen einsetzen, um die Vorteile beider Welten zu kombinieren.

Für die Industrie ergibt sich daraus die Empfehlung, verstärkt auf hybride Verfahren zu setzen. Dabei sollten die bereits stabilen und bewährten Offline-Verfahren beibehalten oder erweiterte, verbesserte Versionen davon eingesetzt werden. Zusätzlich sollten sie mit Online- und adaptiven/intelligenten Verfahren kombiniert werden. Eine Standardisierung von Schnittstellen und die Integration von KI-Verfahren muss gewährleistet werden.

Langfristig ist zu erwarten, dass weiterentwickelte Verfahren wie Physics-Informed Neural Networks und Chirp-Signal Identification eine zentrale Rolle in der Parametererfassung elektrischer Maschinen durch Inverter-Software spielen werden. Sie werden durch Edge-Schnittstellen integriert und die erforderlichen Datensätze für die KI-Anwendungen aus Cloud-Systemen beziehen.

Zusammenfassend lässt sich sagen, dass die Zukunft der Inverter-Software für die Parametererfassung elektrischer Maschinen durch eine zunehmende Automatisierung, Intelligenz und Datenvernetzung gekennzeichnet sein wird. Inverterhersteller, die frühzeitig diese Trends erkennen und auf diese Entwicklungen setzen, können die Effizienz, Zuverlässigkeit und Langlebigkeit elektrischer Maschinen deutlich steigern und Wettbewerbsvorteile sichern.

Abbildungsverzeichnis

Abb. 1 Untergliederung von Invertern nach Funktion und Aufbau 4
Abb. 2 Aufbau eines elektrischen Antriebsstrangs bestehend aus Umrichter, Motor, Last und der zugehörigen Steuerung 5
Abb. 3 Umrichter für Drehstrommotoren 6
Abb. 4 Klassifikation der Parametererfassungsmethoden für elektrische Maschinen 12
Abb. 5 Typenschild eines 2.2 kW Induktionsmotors 15
Abb. 6 Ersatzschaltbild bei Gleichstromspeisung 17
Abb. 7 Ersatzschaltbild der elektrsichen Maschine im Leerlauf 18
Abb. 8 Standstill Identification, bestehend aus Gleichstromversuch und Kurzschlussversuch 21
Abb. 9 Einordnung von Offline-Verfahren im Rahmen des Self-Commissioning-Prozesses moderner Inverter 24
Abb. 10 Ablauf des Self-Commissioning-Prozesses in modernen Invertern mit zugehörigen Offline-Methoden, benötigten Eingangsdaten und jeweils erfassten Maschinenparametern 25
Abb. 11 Identifikation von Statorwiderstand durch DC-Injektion in die d-Achse 30
Abb. 12 FOC-Regelstruktur mit DC-Offseteinspeisung zur Online-Identifikation von Maschinenparametern 30
Abb. 13 Vereinfachtes Schema der Hochfrequenz-Wechselspannungseinspeisung zur Online-Parameteridentifikation 31
Abb. 14 Kombination aus hochfrequenter Signalinjektion und Positionsbeobachter zur Bestimmung von Rotorlage und Drehzahl 35
Abb. 15 Luenberger-Beobachter 36
Abb. 16 Prinzip des modellreferenzierten adaptiven Systems (MRAS) zur Online-Parameteridentifikation 39
Abb. 17 Bestimmung des Statorwiderstands R_s mithilfe eines Fuzzy-Logic-Controllers 45
Abb. 18 Einfache Darstellung der Logik von SVM bei der Parametererfassung . 46
Abb. 19 Ablauf eines Genetic-Algorithmus zur Parametererfassung elektrischer Maschinen 47
Abb. 20 Schematische Darstellung der Parameterschätzung mit PSO/GPSO . . 49
Abb. 21 Ablauf eines Differential-Evolution-Algorithmus zur Parametererfassung elektrischer Maschinen 50

Abb. 22 Neuronales Netz zur Schätzung von Maschinenparametern durch Rückpropagation 51
Abb. 23 Entscheidungsbaum zur Auswahl der Oberkategorie einer geeigneten Parametererfassungsmethode 56
Abb. 24 Übersicht der erfassten Maschinenparameter bei p1910 = 1 (Self-Commissioning) 59
Abb. 25 Struktur des Active Disturbance Rejection Control (ADRC) mit Extended State Observer (ESO) 68
Abb. 26 Aufbau eines Physics-Informed Neural Networks (PINN) zur Zustands- und Parameterbeobachtung elektrischer Maschinen 69

Tabellenverzeichnis

1 Übersicht der Maschinenparameter und zugehörige Formelzeichen 9
2 Übersicht von Methoden zur Maschinenparametererfassung mit zugehörigen Parametern 13
3 Übersicht der Offline-Parametererfassungsverfahren 26
4 Übersicht über injektionsbasierte Online-Methoden 28
5 Übersicht modell- und schätzbasierter Verfahren zur Online-Parametererfassung hinsichtlich Modelltyp, Einsatzbereich und typischer Zielgrößen 34
6 Übersicht der injektionsbasierten und observer-gestützten Online-Parametererfassungsverfahren 43
7 Übersicht der adaptiv/intelligenten Methoden zur Parametererfassung 52
8 Vergleichstabelle zur Übersicht der Methoden zur Parametererfassung elektrischer Maschinen 54
9 Vergleich von SINAMICS-Verfahren zur Parametererfassung 60
10 Übersicht der ACS880-Verfahren und deren Zuordnung zu den in Kapitel 3 behandelten Methoden 61
11 Übersicht der EC-C1200-Verfahren und deren Zuordnung zu den in Kapitel 3 behandelten Methoden 62
12 Vergleich der Softwarelösungen hinsichtlich Automatisierungsgrad, Flexibilität, Kombinationsmöglichkeiten und Online-Funktionen 65
13 Vergleich der Methoden zur Parametererfassung 71

Literaturverzeichnis

ABB Group (2013). *Firmware manual ACS880 primary control program: 3AUA0000085967 Rev F EN*.

– (2020). *ABB Ability™ Condition Monitoring for drives: 3AUA0000189113 REV F EN 11.5*. Hrsg. von ABB Group.

– (2024). *ABB Ability™ Digital Powertrain: 9AKK108469A6266*.

– (2025a). *ABB industrial drives ACS880, single drives 0.55 to 6000 kW*.

– (2025b). *Drives, tools and services*. URL: https://www.abb.com/global/en/areas/motion/drives.

Arnold, H. (2005). „Ein Beitrag zur Identifikation der Parameter der Asynchronmaschine im geregelten Betrieb“. Doktorarbeit. Freiberg, Deutschland: Technischen Universitat Bergakademie Freiberg.

Babiel, G. (2023). *Elektrische Antriebe in der Fahrzeugtechnik*. 5. Auflage. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-40585-4. DOI: 10.1007/978-3-658-40586-1.

Beyer, S. (2018). „Robuste Parameterschätzung für Elektrofahrzeuge“. Doktorarbeit. München: Universität der Bundeswehr München.

Bonifacio, J., N. Amann und R. Kennel (2018). „Online full-parameter identification strategy for IPMSM using voltage signal injection“. In: *2018 20th European Conference on Power Electronics and Applications*. Hrsg. von IEEE. IEEE Press. ISBN: 978 - 9 - 0758 - 1528.

Bose, B. K. (2001). *Modern Power Electronics and AC Drives*. Standard Auflage. Upper Saddle River, NJ: Prentice Hall PTR. ISBN: 0130167436.

Bruhn, M. (2024). *Marketing*. 16. Auflage. Wiesbaden: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-43788-6. DOI: 10.1007/978-3-658-43789-3.

Bui, M. X., D. Xiao und M. F. Rahman (2020). „Improved Sensorless Direct Torque and Flux Control of IPMSM based on On-line Parameter Estimation“. In: *IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society*. Hrsg. von IEEE. IEEE, S. 1009–1014. DOI: 10.1109/IECON43393.2020.9255383.

Chen, Z. (2015). „Sensorless control of permanent magnet synchronous machines with multiple saliencies“. Doktorarbeit. München, Deutschland: Technischen Universität München.

Cherif, B. D. E., M. Chouai, S. Seninete und A. Bendiabdellah (2022). „Machine-Learning-Based Diagnosis of an Inverter-Fed Induction Motor“. In: *IEEE LATIN AMERICA TRANSACTIONS* 20.6, S. 901–911. DOI: 10.1109/TLA.2022.9757372.

Cisneros-González, M., C. Hernandez, R. Morales-Caporal, E. Bonilla-Huerta und M. A. Arjona (2013). „Parameter Estimation of a Synchronous-Generator Two-Axis Model Based on the Standstill Chirp Test“. In: *IEEE Transactions on Energy Conversion* 28.1, S. 44–51. ISSN: 0885-8969. DOI: 10.1109/TEC.2012.2236433.

Danfoss Editron (2025a). *Motor parameter identification*. URL: https://danfosseditron.zendesk.com/hc/en-gb/articles/7332749865885-Motor-parameter-identification.

– (2025b). *Power control for vehicles, machines and marine applications*. URL: https://www.danfoss.com/en/products/dps/electric-converters-motors-and-systems/converters/hv-inverters/#tab-overview.

Dewantoro, G. und Y.-L. Kuo (2011). „Robust speed-controlled permanent magnet synchronous motor drive using fuzzy logic controller“. In: *2011 IEEE International Conference on Fuzzy Systems: (FUZZ-IEEE 2011)*. IEEE, S. 884–888. ISBN: 978-1-4244-7315-1. DOI: 10.1109/FUZZY.2011.6007419.

Elrachid, B., R. Hammoud und B. Oussama (2021). „Parameters Identification of Synchronous Machine Based on Particale Swarm Optimization“. In: *E3S Web of Conferences*. Hrsg. von EDP Sciences. Bd. 336. E3S Web Conf., S. 1–5. DOI: 10.1051/e3sconf/202233600052.

Farkane, A., M. Boutayeb, M. Oudani und M. Ghogho (2025). „PINN-Obs: Physics-Informed Neural Network-Based Observer for Nonlinear Dynamical Systems“. In: S. 1–35. URL: http://arxiv.org/pdf/2507.06712v1.

Fischer, R. und E. Nolle (2022). *Elektrische Maschinen: Aufbau, Wirkungsweise und Betriebsverhalten*. 18., neu bearbeitete Auflage. München, Deutschland: Carl Hanser Verlag GmbH & Co. KG. ISBN: 978-3-446-46912-9.

Fortune Business Insights (2025). *Variable Frequency Drive (VFD) Market Size, Share & Industry Analysis, By Type (AC Drive, DC Drive, Servo Drive), By Power Range (Micro, Low, Medium, High), By Application (Pumps, Electric Fan, HVAC, Conveyors, Extruders, Others), By End-user (Power Generation, Infrastructure, Oil & Gas, Food & Beverages, Mining, Agriculture, and Others), and Regional Forecasts, 2024-2032*. Hrsg. von Fortune Business Insights. URL: https://www.fortunebusinessinsights.com/industry-reports/variable-frequency-drive-market-100876.

Frequency inverter market (2017). URL: https://www.frequencyinverters.org/frequency-inverter-market-759131.html?.

Guedes, J. J., M. F. Castoldi, A. Goedtel, C. M. Agulhari und D. S. Sanches (2017). „Parameters estimation of three-phase induction motors using differential evolution“. In: *Electric Power Systems Research* 154, S. 204–212. ISSN: 03787796. DOI: 10.1016/j.epsr.2017.08.033. URL: http://dx.doi.org/10.1016/j.epsr.2017.08.033.

Hagl, R. (2024). *Elektrische Antriebstechnik*. 4., aktualisierte Auflage. München: Carl Hanser Verlag GmbH & Co. KG.

Jansen, P. L. und R. D. Lorenz (1995). „Transducerless position and velocity estimation in induction and salient AC machines“. In: *IEEE Transactions on Industry Applications* 31.2, S. 240–247. ISSN: 0093-9994. DOI: 10.1109/28.370269.

Jung, A. (2024). *Maschinelles Lernen*. Standardausgabe. Singapore: Springer Nature Singapore. ISBN: 978-981-99-7971-4. DOI: 10.1007/978-981-99-7972-1.

Kampker, A. und H. H. Heimes (2024). *Elektromobilität*. Berlin, Heidelberg: Springer Berlin Heidelberg. ISBN: 978-3-662-65811-6. DOI: 10.1007/978-3-662-65812-3.

Kang Hyo Park, Cheol Moon, Kee Hyun Nam, Mun Kyu Jung und Young Ahn Kwon (2011). „State observer with parameter estimation for sensorless induction motor“. In: *SICE Annual Conference 2011*. Hrsg. von IEEE. IEEE, S. 2967–2970. ISBN: 978-4-907764-39-5.

Kania, J., T. H. Panchal, V. Patel und K. Patel (2011). „Self commissioning: A unique feature of inverter-fed induction motor drives“. In: *2011 Nirma University International Conference on Engineering*. IEEE, S. 1–6. ISBN: 978-1-4577-2168-7. DOI: 10.1109/NUiConE.2011.6153302.

Karanayil, B., M. F. Rahman und C. Grantham (2005). „Stator and Rotor Resistance Observers for Induction Motor Drive Using Fuzzy Logic and Artificial Neural Networks“. In: *IEEE Transactions on Energy Conversion* 20.4, S. 771–780. ISSN: 0885-8969. DOI: 10.1109/TEC.2005.853761.

Kaźmierkowski, M. P., R. Krishnan und F. Blaabjerg (2002). *Control in power electronics: Selected problems*. Standardauflage. Academic Press series in engineering. San Diego, California und London, UK: Academic Press. ISBN: 0124027725.

Konstantinos T. Kampisios (2009). „Electrical Machines Parameter Identification Using Genetic Algorithms“. Doktorarbeit. Nottingham: University of Nottingham.

L. Et-Taaj, Z. Boulghasoul, A. Elkharki, Z. Kandoussi und A. Elbacha (2019). „Extended Kalman Filter for High performances Sensorless Induction Motor drive“. In: *2019 4th World Conference on Complex Systems (WCCS)*. IEEE. ISBN: 978-1-7281-1232-9. DOI: 10.1109/WCCS46515.2019. URL: https://ieeexplore.ieee.org/servlet/opac?punumber=8911252.

Landau, I. D., R. Lozano, M. M'Saad und A. Karimi (2011). *Adaptive Control: Algorithms, Analysis and Applications*. Second Edition. London: Springer London. ISBN: 978-0-85729-663-4. DOI: 10.1007/978-0-85729-664-1.

Li, S., J. Liu, Z. Mai und W. Kong (2024). „Parameter Identification of Induction Motors Based on D-Axis Signal Injection“. In: *2024 7th International Conference on Power and Energy Applications (ICPEA)*. Hrsg. von IEEE. IEEE, S. 266–272. ISBN: 979-8-3503-5611-3. DOI: 10.1109/ICPEA63589.2024.10784945.

Li, X. und R. Kennel (2021). „General Formulation of Kalman-Filter-Based Online Parameter Identification Methods for VSI-Fed PMSM“. In: *IEEE Transactions on Industrial Electronics* 68.4, S. 2856–2864. ISSN: 0278-0046. DOI: 10.1109/TIE.2020.2977568.

Li Liu, David A. Cartes und Wenxin Liu (2007). „Particle Swarm Optimization Based Parameter Identification Applied to PMSM“. In: *Proceedings of the 2007 American Control Conference*. Hrsg. von IEEE. IEEE, S. 2955–2960. ISBN: 1-4244-0988-8. DOI: 10.1109/ACC.2007.4282649.

Liu, K. und Z. Zhu (2017). „Fast Determination of Moment of Inertia of Permanent Magnet Synchronous Machine Drives for Design of Speed Loop Regulator“. In: *IEEE Transactions*

on Control Systems Technology 25.5, S. 1816–1824. ISSN: 1063-6536. DOI: 10.1109/TCST.2016.2615090.

Liu, S., Q. Wang, G. Wang, B. Li, D. Ding, G. Zhang und D. Xu (2023). „Virtual-Axis Injection Based Online Parameter Identification of PMSM Considering Cross Coupling and Saturation Effects“. In: *IEEE Transactions on Power Electronics* 38.5, S. 5791–5802. ISSN: 0885-8993. DOI: 10.1109/TPEL.2023.3236031.

Liu, Y., J. Fang, K. Tan, B. Huang und W. He (2020). „Sliding Mode Observer with Adaptive Parameter Estimation for Sensorless Control of IPMSM“. In: *Energies* 13.22, S. 1–18. DOI: 10.3390/en13225991.

Lu, Q., S. Gao, T. Zhang, S. Zheng und L. Mo (2022). „Rotor Position Estimation Strategy Based on Rotating High-Frequency Voltage Injection Using Synchronous Frequency Filter“. In: *Applied Sciences* 12.23, S. 11945. DOI: 10.3390/app122311945.

Luenberger, D. G. (1971). „An introduction to observers“. In: *IEEE Transactions on Automatic Control* 16.6, S. 596–602. ISSN: 0018-9286. DOI: 10.1109/TAC.1971.1099826.

Marulanda-Durango, J., A. Escobar-Mejía, A. Alzate-Gómez und M. Álvarez-López (2021). „A Support Vector machine-Based method for parameter estimation of an electric arc furnace model“. In: *Electric Power Systems Research* 196, S. 1–24. ISSN: 03787796. DOI: 10.1016/j.epsr.2021.107228.

McElveen, R. und M. Melfi (2015). „Locked-rotor test methods for induction motors investigated“. In: *2015 IEEE Petroleum and Chemical Industry Committee Conference (PCIC)*. IEEE, S. 1–9. ISBN: 978-1-4799-8501-2. DOI: 10.1109/PCICON.2015.7435098.

Mertens, K. (2022). *Photovoltaik: Lehrbuch zu Grundlagen, Technologie und Praxis*. 6., aktualisierte und erweiterte Auflage. München, Deutschland: Carl Hanser Verlag GmbH & Co. KG. ISBN: 978-3-446-47194-8.

Michel, M. (2008). *Leistungselektronik: Einführung in Schaltungen und deren Verhalten*. 4., bearbeitete Auflage. Berlin, Heidelberg, Deutschland: Springer-Verlag Berlin Heidelberg. ISBN: 978-3-540-75610-1. DOI: 10.1007/978-3-540-75611-8.

Mohan, N., T. M. Undeland und Joseph, William P. Robbins Olivia (2023). „Power Electronics: Converters, Applications and Design“. In: *Cosmic Journal of Physics* 2.1, S. 1–40. DOI: 10.13140/RG.2.2.36786.58562.

Mrugowsky, H. (2015). *Drehstrommaschinen im Inselbetrieb: Modellbildung – Parametrierung – Simulation*. 2. Auflage. Wiesbaden, Deutschland: Springer Fachmedien Wiesbaden. ISBN: 978-3-658-08989-4. DOI: 10.1007/978-3-658-08990-0.

Nalakath et al. (2021). „Method for determining motor parameters during comissioning of synchronous and asynchronous electric motors and related commissioned electric motor: Patent“. US 11,075,596 B2.

Odhano, S. A. (2014). „Self-Commissioning of AC Motor Drives“. Doktorarbeit. Politecnico di Torino. DOI: 10.6092/polito/porto/2543100.

Odhano, S. A., P. Pescetto, H. A. A. Awan, M. Hinkkanen, G. Pellegrino und R. Bojoi (2019). „Parameter Identification and Self-Commissioning in AC Motor Drives: A Technology Status Review“. In: *IEEE Transactions on Power Electronics* 34.4, S. 3603–3614. ISSN: 0885-8993. DOI: 10.1109/TPEL.2018.2856589.

Perera, A. und R. Nilsen (2022). „Recursive Prediction Error Gradient-Based Algorithms and Framework to Identify PMSM Parameters Online“. In: URL: http://arxiv.org/pdf/2209.05094v1.

Qi, X., C. Sheng, Y. Guo, T. Su und H. Wang (2023). „Parameter Identification of a Permanent Magnet Synchronous Motor Based on the Model Reference Adaptive System with Improved Active Disturbance Rejection Control Adaptive Law“. In: *Applied Sciences* 13.21, S. 12076. DOI: 10.3390/app132112076.

Richter, J. (2016). „Modellbildung, Parameteridentifikation und Regelung hoch ausgenutzter Synchronmaschinen“. Doktorarbeit. Karlsruhe, Deutschland: Karlsruher Institut für Technologie Elektrotechnisches Institut. DOI: 10.5445/KSP/1000057097.

Rockwell Automation (2025). *FactoryTalk Analytics InfoPlatform Service Installation and Configuration Guide: Rev01*.

Sadek, S. M., M. H. Mostafa und A. K. Ryad (2022). „Comparison between flux estimation methods for direct torque controlled permanent magnet synchronous motors“. In: *International Journal of Power Electronics and Drive Systems (IJPEDS)* 13.4, S. 2324–2335. ISSN: 2088-8694. DOI: 10.11591/ijpeds.v13.i4.pp2324-2335.

Salgarkar, R. (2024). *Top Companies in Variable Frequency Drive Industry*. URL: https://www.marketsandmarkets.com/ResearchInsight/variable-frequency-drive-market.

Sanjay, S. O. V. und R. M. Pidaparti (2016). „Graded Particle Swarm Optimization (GPSO)“. In: *2016 International Conference on Robotics: Current Trends and Future Challenges (RCTFC)*. IEEE, S. 1–6. ISBN: 978-1-5090-3342-3. DOI: 10.1109/RCTFC.2016.7893404.

Schierling, H. (1988). „Self-Commissioning - A novel feature of modern inveter-fed induction motor drives“. In: *Third International Conference on Power Electronics and Variable-Speed Drives*. Hrsg. von IET. IET, S. 287–290. ISBN: 0-85296-364-5.

Schneider Electric (2019). *EcoStruxure Machine Advisor: v1.0*.

Schröder, D. (2012). *Leistungselektronische Schaltungen: Funktion, Auslegung und Anwendung*. 3. Auflage. Berlin, Heidelberg, Deutschland: Springer-Verlag Berlin Heidelberg. ISBN: 978-3-642-30103-2. DOI: 10.1007/978-3-642-30104-9.

Schröder, D. und J. Böcker (2021). *Elektrische Antriebe – Regelung von Antriebssystemen*. 5. Auflage. Berlin, Heidelberg, Deutschland: Springer-Verlag Berlin Heidelberg. ISBN: 978-3-662-62699-3. DOI: 10.1007/978-3-662-62700-6.

Siemens AG (2004). *SINAMICS S120 Listenhandbuch: Ausgabe 05.2004 / Bestellnummer: 6SL3 097-2AP00-0AP1*. Erlangen, Deutschland.

Siemens AG (2009). *SINAMICS G120 Control Units CU230P-2 Funktionshandbuch: A5E02430408A AA*. Hrsg. von Siemens AG. Nürnberg, Deutschland.
– (2012). *Commissioning Manual SINAMICS S120: 6SL3097-4AF00-0BP2*. Nürnberg, Deutschland.
– (2016). *SINAMICS S120 mit Starter: Inbetriebnahmehandbuch: 6SL3097-4AF00-0AP5*. Nürnberg, Deutschland.
– (2021). *Analyze MyDrives /Cloud: A5E50681242B AC*. Nürnberg, Deutschland.
– (2023). *SIDRIVE IQ Fleet: A5E50161948B AP*. Nürnberg, Deutschland.
– (2025a). *Industrial Edge Platform Operation: Setup, Operate & Utilize: A5E53639678-AG*. Nürnberg, Deutschland.
– (2025b). *Insights Hub Private Cloud Software: Documentation: v1.14*. Nürnberg, Deutschland.
– (2025c). *Siemens Industrial Edge Hub*. URL: https://xcelerator.siemens.com/global/en/all-offerings/products/i/industrial-edge-hub.html.
– Hrsg. (2025d). *SINAMICS Frequenzumrichter*. URL: https://www.siemens.com/de/de/produkte/antriebstechnik/umrichter.html.
Ta, C.-M., T. Uchida und Y. Hori (2001). „MRAS-based speed sensorless control for induction motor drives using instantaneous reactive power“. In: *IECON'01. 27th Annual Conference of the IEEE Industrial Electronics Society*. IEEE, S. 1417–1422. ISBN: 0-7803-7108-9. DOI: 10.1109/IECON.2001.975989.
Tang, J., Y. Yang, F. Blaabjerg, J. Chen, L. Diao und Z. Liu (2018). „Parameter Identification of Inverter-Fed Induction Motors: A Review“. In: *Energies* 11.9, S. 2194. DOI: 10.3390/en11092194.
Toudert, O. (2023). „Novel Rotor Position Extraction Based on Rotating High-Frequency Voltage Injection for Permanent Magnet Synchronous Machine Drives at Low or Zero Speeds“. In: *Rev. Roum. Sci. Techn.– Électrotechn. et Énerg.* 68.2, S. 188–193. DOI: 10.59277/RRST-EE.2023.68.2.12.
Wang, P., K. Lin, M. Lin, A. Yang, F. Fu und J. Ai (2021). „Online multi–parameter estimation of permanent magnet synchronous machine with step–pulse injection“. In: *IET Electric Power Applications* 15.2, S. 186–199. ISSN: 1751-8660. DOI: 10.1049/elp2.12014.
Yaskawa America INC. (2021). *YaskawaCockpit: 937.847.6200*. Miamisburg, OH 45342.
Zhong L., M. F. Rahman, W. Y. Hu und K. W. Lim (1997). „Analysis Of Direct Torque Control In Permanent Magnet Synchronous Motor Drives“. In: *IEEE TRANSACTIONS ON POWER ELECTRONICS* 12.3, S. 528–536.
Zhu, Q. Z. und X. M. Wu (2024). *Sensorless Control of Permanent Magnet Synchronous Machine Drives*. Standard Auflage. Piscataway, NJ: IEEE Press. ISBN: 9781394194353.