

Abstrakte Verhaltensmodellierung und
Zustandsüberwachung integrierter Schaltungen
hinsichtlich Umgebungs- und Degradationseinflüssen

Maike Taddiken M.Sc.

Universität Bremen 2024

Abstrakte Verhaltensmodellierung und Zustandsüberwachung integrierter Schaltungen hinsichtlich Umgebungs- und Degradationseinflüssen

Vom Fachbereich Physik und Elektrotechnik
der Universität Bremen

zur Erlangung des akademischen Grades
DOKTOR-INGENIEURIN (Dr.-Ing.)
genehmigte Dissertation

von

Maike Taddiken M.Sc.
aus Delmenhorst

Referent:	Professor Dr.-Ing. Steffen Paul
Korreferent:	Apl. Prof. Dr.-Ing. habil. Helmut Gräß
Eingereicht am:	12.10.2023
Tag des Promotionskolloquiums:	14.02.2024

Kurzfassung

Die technologischen Fortschritte bei der Herstellung moderner integrierter Schaltungen ermöglichen die Fertigung in immer kleineren Strukturgrößen, die mit signifikanten Steigerungen der Leistung und Effizienz einhergehen. Die geringen Strukturgrößen bringen jedoch auch Herausforderungen mit sich, da sie sehr anfällig gegenüber Störeinflüssen wie Prozessvariation, Spannungs- und Temperaturschwankungen sowie Alterung sind. Diese Faktoren, die als PVTA bezeichnet werden, können die Funktionalität der Schaltungen während des Betriebs beeinträchtigen. Daher ist für die Entwicklung zuverlässiger Schaltungen eine frühzeitige Berücksichtigung dieser Einflüsse im Entwurfsprozess unabdingbar. Die Simulation dieser Effekte ist, aufgrund der zu berücksichtigenden physikalischen Abhängigkeiten, meist lediglich auf einem geringen Abstraktionsniveau wie der Transistorebene möglich. Für große Systeme ist diese Art der Simulation jedoch angesichts der Komplexität und des damit verbundenen Rechenaufwands nicht praktikabel, so dass eine Betrachtung auf höheren Abstraktionsebenen erforderlich ist. Dafür werden Modelle und entsprechende Modellierungsmethoden benötigt, welche in der Lage sind, die relevanten Eigenschaften und Abhängigkeiten der betrachteten Schaltungskomponenten darzustellen. Trotz der Berücksichtigung der möglichen Einflüsse und Verwendung von Sicherheitsmarge im Entwurfsprozess kann es während des Betriebs zu Veränderungen des Schaltungsverhaltens kommen, was insbesondere in sicherheitskritischen Anwendungsfeldern von höchster Relevanz ist. In diesen Fällen können zusätzliche Monitoringstrukturen Aufschluss über den aktuellen Zustand der Schaltung und über mögliche Veränderungen geben.

Diese Arbeit konzentriert sich in diesem Zusammenhang auf zwei Themen: die Entwicklung einer neuartigen Modellierungsmethode für stochastische Verhaltensmodelle und die Untersuchung einer Monitoring-Methode für die Überwachung analoger Schaltungen.

Die Modellierungsmethodik befasst sich mit der Erstellung von stochastischen Verhaltensmodellen unter Verwendung von Response-Surface-Modellen (RSM), die die stochastische Verteilung von Schaltungseigenschaften aufgrund von Prozessvariationen, Umgebungsbedingungen und Alterung berücksichtigen. Verschiedene Methoden, einschließlich der Erfassung von Variationen der Normal- und Lognormalverteilung und der Modellierung nicht-normalverteilter Variationen, werden entwickelt und durch Simulationen an verschiedenen Beispielschaltungen analysiert.

Im zweiten Teil der Arbeit wird ein Monitoring-Verfahren untersucht, welches die Koeffizienten digitaler adaptiver Filter zur Überwachung des Zustands analoger Schaltungen nutzt. RSM-basierte Verhaltensmodelle werden eingesetzt, um das Referenzsignal des idealen Schaltungsverhaltens zu erzeugen. Das Monitoring-Verfahren erlaubt zudem die Überwachung der Degradierung der Schaltung bei fortschreitender Alterung. Das Verfahren wird anhand von Simulationen sowie einer messtechnischen Auswertung einer Beispielschaltung untersucht.

Abstract

Technological advances in the fabrication of modern integrated circuits enable manufacturing in ever-smaller structure sizes, which are associated with significant increases in performance and efficiency. However, the small structure sizes also introduce challenges as they are highly susceptible to influences from process variation, voltage and temperature fluctuations, and aging. These factors, referred to as PVTA, can affect the functionality of the circuits during operation. Therefore, early consideration of these influences in the design process is essential for the development of reliable circuits. Simulation of these effects is usually only possible at a low level of abstraction, such as the transistor level, due to the physical dependencies that need to be considered. For large systems, however, this type of simulation is not feasible in view of the complexity and the associated computational effort, so that consideration at higher levels of abstraction is required. This requires models and corresponding modeling methods that are capable of representing the relevant properties and dependencies of the circuit components. Despite a comprehensive design taking into account the possible influences and the use of safety margins, shifts in the circuit behavior can occur during operation, which is of utmost relevance especially in safety-critical applications. In these cases, additional monitoring structures can provide information about the current state of the circuit and about possible shifts in performance.

This thesis focuses on two topics: the development of a novel modeling methodology for stochastic behavioral models and the investigation of a monitoring methodology for analog circuit monitoring.

The modeling methodology addresses the creation of stochastic behavioral models using Response Surface Models (RSMs) that account for the stochastic distribution of circuit characteristics due to process variation, environmental conditions, and aging. Various methods, including capturing variations of the normal and lognormal distributions and modeling non-normally distributed variations, are developed and analyzed through simulations on various example circuits.

In the second part of the thesis, a monitoring method that uses the coefficients of digital adaptive filters to monitor the state of analog circuits is investigated. RSM-based behavioral models are used to generate the reference signal of the ideal circuit behavior. The monitoring procedure also allows monitoring of the degradation of the circuit over time. The evaluation of the method is performed using simulations as well as measurements of an example circuit.


Vorwort

Diese Arbeit ist im Rahmen meiner Tätigkeit als wissenschaftliche Mitarbeiterin am Institut für theoretische Elektrotechnik und Mikroelektronik (ITEM) in der Arbeitsgruppe Kommunikationselektronik an der Universität Bremen entstanden. An dieser Stelle möchte ich mich herzlichst bei Herrn Professor Steffen Paul für die Ermöglichung sowie die wertvolle Unterstützung meiner Dissertation durch fachliche Expertise und zahlreiche konstruktive Ratschläge bedanken. Außerdem danke ich Herrn Professor Helmut Gräß für die Übernahme des Korreferats. Ein besonderer Dank gilt Frau Dr. Dagmar Peters-Drolshagen für die Ermöglichung und Betreuung des LEMON Projekts sowie für die fachlichen Ratschläge.

Bei allen aktuellen und ehemaligen Mitarbeitenden des ITEM möchte ich mich für die Jahre der erfolgreichen Zusammenarbeit bedanken, für die gute Gemeinschaft und die inspirierenden Gespräche in den Kaffeepausen. Ein herzlicher Dank an meinen Bürokollegen Theodor Hillebrand für endlose fachliche Diskussionen, viele konstruktive Kommentare und Spaß bei der Arbeit, sowie an Konstantin Bajer und Sascha Heißen für die Zusammenarbeit und gemeinsame Arbeit an Veröffentlichungen. Bei Valerie Gerdes und Alexandra Avenius möchte ich mich für die immerwährende Hilfsbereitschaft und die vielen Gespräche bedanken.

Vielen Dank an Nina Haug für die vielen Gespräche über das Uni-Universum, die gemeinsamen virtuellen Schreibtreffen und für Larry.

Abschließend möchte ich einen ganz besonderen Dank an meine Familie richten, die mir immer unterstützend und mit viel Zuspruch zur Seite gestanden hat. Danke!



Inhaltsverzeichnis

1. Einleitung	1
1.1. Eigener Beitrag	2
1.2. Gliederung	3
2. Zuverlässigkeit	5
2.1. Definition von Zuverlässigkeit	5
2.1.1. Systemzuverlässigkeit	7
2.2. Zuverlässigkeit in integrierten Schaltungen	8
2.2.1. Prozessvariation	9
2.2.2. Spannung und Temperatur	10
2.2.3. Alterung	12
2.3. Zuverlässigkeit im Entwurfsprozess integrierter Schaltungen	15
2.3.1. Monte-Carlo- und Corner-Simulation	16
2.3.2. Alterungssimulation	17
2.4. Zusammenfassung	20
3. PVTA Verhaltensmodellierung	21
3.1. Grundlagen der Schaltungsmodellierung	21
3.1.1. Verhaltens- und Performancemodelle	21
3.1.2. Response Surface Modellierung	25
3.1.2.1. Polynomiale Modelle	28
3.1.2.2. Radiale Basisfunktionen	28
3.1.2.3. Matérn-Funktionen	30
3.1.3. Statistische Versuchsplanung	31
3.1.4. Modellgenauigkeit	33
3.2. Schaltungsmodellierung: Stand der Technik	35
3.3. RSM-basierte Verhaltensmodelle	36
3.4. Stochastische Verhaltensmodelle	38
3.4.1. Performancemodellierung parametrischer Verteilungen	42
3.4.1.1. Betrachtung von Korrelationen	45
3.4.2. Performancemodellierung nicht-normaler Verteilungen	46
3.4.2.1. LUT-basiertes Modell	48
3.4.2.2. RSM-basiertes Modell	48

3.4.2.3. Slice Sampling	49
3.5. Automatisierte Modellerstellung	50
3.6. Zusammenfassung	54
4. PVTA-Modelle integrierter Schaltungskomponenten	57
4.1. Beispielschaltungen	57
4.1.1. OTA-Schaltung	57
4.1.2. Komparator	58
4.1.3. Common-Source-Verstärker	59
4.2. Stochastische Verhaltensmodelle mit parametrischen Verteilungen	59
4.2.1. Einzel- oder Gesamtsystemmodell	59
4.2.2. Hierarchische Modellierung	63
4.2.2.1. Unkorreliertes System	63
4.2.2.2. Korreliertes System	66
4.3. Stochastische Verhaltensmodelle nicht-normaler Verteilungen	71
4.3.1. LUT-basiertes Modell	71
4.3.2. RSM-basiertes Modell	75
4.4. Zusammenfassung	77
5. Monitoring analoger Schaltungskomponenten	79
5.1. Überblick zu Test- und Monitoring-Verfahren	80
5.2. Grundlagen adaptiver Filter	82
5.2.1. Adaptive FIR-Filter	82
5.2.2. LMS-Algorithmus	83
5.3. Monitoring-System	84
5.3.1. Adaptive Filterstruktur	85
5.3.2. Referenzsignal	87
5.3.3. Bestimmung der aktuellen Schaltungsperformance	88
5.3.4. Genauigkeit des Monitoring	89
5.4. Zusammenfassung	90
6. Monitoring-Ergebnisse	91
6.1. Simulative Evaluation des Monitoring-Verfahrens	91
6.1.1. Beispielschaltungen	92
6.1.1.1. Differentieller Cascode-Operationsverstärker	93
6.1.1.2. Folded-Cascode-Operationsverstärker	94
6.1.2. Zustandsüberwachung ohne Prozessvariation	95
6.1.2.1. Degradationsmonitoring	99
6.1.3. Monitoring mit Prozessvariation	101
6.1.3.1. Prozessvariation ohne Alterung	101
6.1.3.2. Prozessvariation mit Alterung	104
6.1.4. Vorhersage der Restlebenszeit	105

6.2. Messtechnische Evaluation des Monitoring-Verfahrens	108
6.2.1. Testsystem	108
6.2.1.1. Verhaltensmodell	109
6.2.1.2. Messaufbau	110
6.2.2. Messergebnisse	111
6.2.2.1. Variation von Versorgungsspannung und Lastwiderstand . . .	112
6.2.2.2. Variation der Temperatur	115
6.3. Zusammenfassung	120
7. Zusammenfassung und Ausblick	121
7.1. Zusammenfassung	121
7.2. Ausblick	122
A. Dimensionierung der Beispielschaltungen	125
A.1. OTA System	126
A.1.1. Beta-Multiplier	126
A.1.2. Distributionsnetzwerk	127
A.1.3. OTA	128
A.2. Differentieller Cascode-Operationsverstärker	129
A.3. Folded-Cascode-Operationsverstärker	130
B. Auszug des Datenblatts LT1813	131
Abkürzungsverzeichnis	133
Symbolverzeichnis	137
Literaturverzeichnisse	139
Referenzen	139
Eigene Publikationen	147



1 Einleitung

Moderne integrierte Schaltungen sind äußerst komplex und setzen sich aus einer Vielzahl an Transistoren zusammen. So bestehen digitale Schaltungen wie CPUs aus mehreren Milliarden einzelnen Transistoren. Die Fortschritte in den modernen Fertigungstechnologien ermöglichen es, immer kleinere Strukturgrößen zu realisieren. Der Halbleiterhersteller TSMC produziert beispielsweise seit 2020 Chips in 5nm-Technologie in Massenproduktion und arbeitet an der Bereitstellung des 3nm Prozesses [TSM23]. Diese kleinen Technologieknoten werden hauptsächlich für die Produktion digitaler integrierter Schaltungen verwendet, welche leichter skalierbar sind und somit aufgrund der kleineren Strukturgrößen Fortschritte bzgl. Performance sowie Platz- und Energieverbrauch erreichen. Doch auch analoge Schaltungen werden in immer kleineren Strukturen, bspw. 14nm FinFET, gefertigt.

Eine der grundlegenden Problematiken kleiner werdender Strukturgrößen ist der zunehmende Einfluss störender Faktoren, welche die Funktionalität der integrierten Schaltungen negativ beeinflussen können. Zu den am wichtigsten und daher am häufigsten betrachteten Einflüssen zählen Prozessvariation, Spannungs- und Temperaturschwankungen sowie Alterung. Diese werden unter dem Begriff PVTA (***P**rocess, **V**oltage, **T**emperature, **A**geing*) zusammengefasst. Während Prozessvariation durch den Herstellungsprozess an sich bedingt ist und zu einer anfänglichen stochastischen Verteilung einzelner Transistorparameter führt, welche eine Abweichung des Schaltungsverhaltens vom Nominalverhalten nach sich ziehen, beeinflussen die anderen genannten Effekte (VTA) das Verhalten der Schaltung während des Betriebs. Insbesondere Alterung kann zu einer zunehmenden Veränderung der Schaltungseigenschaften über die Lebenszeit hinweg führen, was als Degradierung bezeichnet wird. Diese alterungsabhängige Degradierung ist zudem stark abhängig von den Betriebsbedingungen und stellt somit eine besondere Herausforderung bei der Berücksichtigung während des Designs einer integrierten Schaltung dar. Wie bereits erwähnt, sind moderne Schaltungen sehr komplex und bestehen aus einer Vielzahl an einzelnen Schaltungskomponenten, sowohl auf der digitalen als auch analogen Ebene. Um die Funktionalität eines Gesamtsystems untersuchen und validieren zu können, ist die Simulation dieses Systems während des Entwurfs notwendig. Die Berücksichtigung der zuvor beschriebenen Einflussfaktoren ist dabei unerlässlich, um die Einhaltung der Spezifikationen unter den verschiedenen zu erwartenden Bedingungen garantieren zu können. Entsprechende Modelle zur Simulation der PVTA-Effekte sind meist lediglich auf einer niedrigen Abstraktionsebene wie der Transistorebene verfügbar. Auf dieser niedrigen Abstraktionsebene ist jedoch die Anzahl an Bauteilen begrenzt, für die sich die Komplexität der Simulation in einem vertretbaren

Rahmen bzgl. Simulationszeit und -aufwand bewegt. Für die Untersuchung einer größeren Schaltung wird daher eine Betrachtung des Gesamtsystems auf einer höheren Abstraktionsebene angestrebt. Die Betrachtung auf verschiedenen Ebenen erfordert die Entwicklung von Modellierungsmethoden, welche die Berücksichtigung verschiedener Effekte mit vertretbaren Einbußen an Genauigkeit erlauben.

Verhaltensmodelle einzelner Subkomponenten können zudem eingesetzt werden, um die Intellectual Property eines Schaltungsdesigns zu schützen. Dies ist insbesondere wichtig, wenn einzelne Komponenten von unterschiedlichen Herstellern entwickelt werden und in einem Gesamtsystem integriert werden sollen. In diesen Fällen kann es wünschenswert sein, dass keine detaillierten Informationen über das Design, bspw. in Form einer Netzliste, an ein evtl. konkurrierendes Unternehmen übergeben werden. Stattdessen wird lediglich ein Verhaltensmodell, welches die Funktionalität und die Abhängigkeiten der Subkomponente möglichst genau darstellen kann, weitergegeben.

Die Berücksichtigung der Degradierungseffekte stellt heute einen wichtigen Teil des zuverlässigkeitsorientierten Entwurfsprozesses dar; das sog. *Design for Reliability* (DfR) umfasst im Schaltungsdesign Verfahren, welche die Einhaltung der Zuverlässigkeitsanforderungen über die gesamte Lebenszeit sicherstellen sollen. Trotzdem kann eine Verschiebung der charakteristischen Schaltungseigenschaften aufgrund der verschiedenen Einflüsse während der Lebenszeit häufig nicht gänzlich ausgeschlossen werden. Insbesondere für sicherheitskritische Applikationen ist daher die Kenntnis über den aktuellen Zustand der Schaltung, die Detektion von Alterung sowie eine darauf basierende Vorhersage bzgl. der verbleibenden Restlebenszeit (*remaining useful lifetime*, RUL) notwendig. Zu diesem Zweck werden entsprechende Monitoring-Verfahren benötigt, welche den aktuellen Zustand der Schaltung sowie Veränderungen über die Zeit ermitteln können.

1.1. Eigener Beitrag

Der eigene Beitrag dieser Arbeit unterteilt sich in zwei Themenbereiche: Die Entwicklung einer neuartigen Modellierungsmethode für stochastische Performance- und Verhaltensmodelle sowie die Untersuchung eines Monitoring-Verfahrens zur Überwachung analoger Schaltungen.

Für die Verwendung von Response-Surface-Modellen (RSM) zur Modellierung des Schaltungsverhaltens, auch unter Zuverlässigkeitsaspekten, gibt es bereits einige in der Literatur beschriebene Ansätze. Basierend auf diesen bereits existierenden Modellierungsmethoden unter Verwendung von RSMs wurden verschiedene neuartige Methoden zur Erstellung stochastischer Performancemodelle entwickelt und zu einem umfassenden Modellierungsverfahren zusammengefasst. Dies ermöglicht die Berücksichtigung der durch Prozessvariation hervorgerufenen stochastische Verteilung der Schaltungseigenschaften sowie deren Verschiebung durch variierende Umgebungsbedingungen und Alterung auf höheren Abstraktionsebenen. Somit entsteht die Möglichkeit zur Erstellung von PVTA-Verhaltensmodellen. Die Methoden umfassen zum einen die Erfassung normal- und lognormal verteilter Variation der Schaltungseigenschaften, wobei die Veränderung der stochastischen Verteilung aufgrund von VTA-Einflüssen durch die RSM-Modellierung von Mittelwert und Standardabweichung erfasst wird. Zur Berücksichtigung

einfacher Korrelationen bei der Erstellung von hierarchisch aufgebauten Verhaltensmodellen wird die Veränderung der Standardabweichung betrachtet. Darüber hinaus können auch nicht-normal-verteilte Variationen mittels Bestimmung der Wahrscheinlichkeitsdichtefunktion durch Kerndichteschätzung oder Gaussian Mixture Models modelliert werden. Hier wird zwischen einem *Look-Up-Table-* (LUT)- und einem RSM-basierten Ansatz unterschieden. Die beschriebenen Modellierungsverfahren werden an verschiedenen Beispielschaltungen simulativ untersucht und die Ergebnisse hinsichtlich Genauigkeit und Simulationsaufwand bewertet.

Wie bereits erwähnt, können Verhaltensmodelle zu verschiedenen Zwecken eingesetzt werden. Eine dieser Einsatzmöglichkeiten wird im zweiten Teil dieser Arbeit beleuchtet. Hier wird ein Ansatz für ein Monitoring-Verfahren untersucht, welches unter Verwendung der Koeffizienten adaptiver digitaler Filter den aktuellen Schaltungszustand und die Performancewerte einer analogen Schaltung überwacht. Bei dem Monitoring-Verfahren wird auf die im ersten Teil der Arbeit verwendeten RSM-basierten Verhaltensmodelle zurückgegriffen, um anhand des damit bestimmten Referenzsignals des idealen Schaltungsverhaltens die reale aktuelle Performance ermitteln zu können. Durch die Überwachung über einen längeren Zeitraum kann zudem der Degradierungszustand der Schaltung bestimmt werden. Das Monitoring-Verfahren wird zunächst anhand von Beispielschaltungen simulativ untersucht, wobei auch die Berücksichtigung von Degradierung erfolgt. Anschließend findet eine messtechnische Evaluation statt.

1.2. Gliederung

In Kapitel 2 werden zunächst die Grundlagen von Zuverlässigkeit in integrierten Schaltungen betrachtet. Dazu gehört zum einen der Begriff der Zuverlässigkeit an sich, als auch die verschiedenen in dieser Arbeit betrachteten PVTA-Einflussfaktoren auf das Verhalten und die Zuverlässigkeit integrierter Schaltungen. Zudem wird die Berücksichtigung dieser Einflüsse in den Simulationen während des Entwurfsprozesses beleuchtet. Das 3. Kapitel beschäftigt sich mit der Verhaltensmodellierung. Zunächst wird auf die Grundlagen der Schaltungsmodellierung mittels Response-Surface-Modellen, wie sie in dieser Arbeit verwendet wird, eingegangen. Anschließend werden die in dieser Arbeit entwickelten Modellierungsverfahren zur Erstellung stochastischer Verhaltensmodelle vorgestellt, welche die Berücksichtigung der PVTA-Einflüsse ermöglichen. In Kapitel 4 werden Beispiele zu den verschiedenen in Kapitel 3 präsentierten Modellierungsverfahren gezeigt.

Der Ansatz eines Monitoring-Verfahrens zur Überwachung der Performance integrierter Schaltungskomponenten auf Basis digitaler adaptiver Filter wird in Kapitel 5 erläutert. Zunächst erfolgt hier eine Betrachtung der benötigten Grundlagen für das entwickelte Monitoring-Verfahren, welches zudem auf die zuvor beschriebenen RSM-basierten Verhaltensmodelle zurückgreift. In Kapitel 6 werden die simulativen und experimentellen Ergebnisse für das Monitoring-Verfahren beschrieben.

Ein zusammenfassendes Fazit sowie ein Ausblick auf mögliche Weiterentwicklungen der in dieser Arbeit vorgestellten Methoden erfolgt in Kapitel 7.

In diesem Kapitel werden zunächst die grundlegenden Definitionen von Zuverlässigkeit sowie deren Betrachtung im Systemkontext erläutert. Darüber hinaus erfolgt eine Beschreibung der in integrierten Schaltungen auftretenden Zuverlässigkeitseffekte sowie deren Berücksichtigungsmöglichkeiten während des Entwurfsprozesses. Diese werden unter dem Begriff PVTA (Variationen durch Prozess-, Spannungs (Voltage)- und Temperaturschwankungen sowie Alterung) zusammengefasst. Auf Grundlage dieser Effekte und ihrer Bedeutung bei der Entwicklung integrierter Schaltungskomponenten erfolgt die anschließende Entwicklung von PVTA-Verhaltensmodellen zur Berücksichtigung von Zuverlässigkeit auf verschiedenen Abstraktionsebenen im Gesamtsystemkontext.

2.1. Definition von Zuverlässigkeit

Der Begriff Zuverlässigkeit kann zum einen zusammenfassend „zur Beschreibung der Verfügbarkeit und ihrer Einflussfaktoren Funktionsfähigkeit, Instandhaltbarkeit und Instandhaltungsbereitschaft“ [Ver06] verwendet werden. Die in dieser Arbeit verwendete Definition von Zuverlässigkeit als Kenngröße eines Systems beschreibt die Wahrscheinlichkeit, dass ein System seine vordefinierte Funktionen unter bestimmten Bedingungen über ein spezifiziertes Zeitintervall hin erfüllt [HAN98]. Die Fehlerverteilungsfunktion $F(t)$ gibt dabei die Wahrscheinlichkeit an, dass in einem System bis zum Zeitpunkt t eine Fehlfunktion auftritt. Diese korrespondiert mit der Zuverlässigkeit über den Zusammenhang

$$F(t) = 1 - R(t) \quad (2.1)$$

wobei $R(t)$ die Zuverlässigkeitsfunktion, auch Überlebensfunktion genannt, darstellt [JH17]. $R(t)$ gibt die Wahrscheinlichkeit an, dass bis zum Zeitpunkt t kein Fehler auftritt. Über die zugehörige Wahrscheinlichkeitsdichteverteilung $f(t)$ lässt sich die sogenannte Fehler- bzw. Ausfallrate $\lambda(t)$ definieren:

$$\lambda(t) = \frac{f(t)}{R(t)} = \frac{\frac{d}{dt} F(t)}{R(t)}. \quad (2.2)$$

Die Fehlerrate gibt somit an, wie viele Systeme in einem bestimmten Zeitintervall $[t, t + \Delta t]$ im Mittel ausfallen und kann für eine größere Anzahl an Systemen statistisch ermittelt werden. Eine gängige Darstellung des zeitlichen Verlaufs der Fehlerrate ist die in Abbildung 2.1 dargestellte

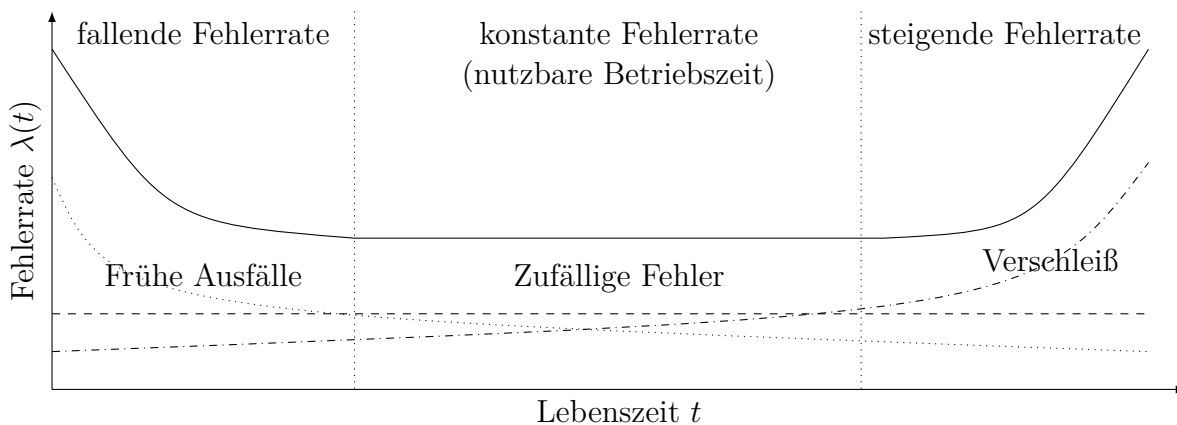


Abbildung 2.1.: Badewannenkurve Fehlerrate [HAN98, JH17]

sogenannte Badewannenkurve. Diese weist drei charakteristische Bereiche auf, welche sich durch eine zunächst fallende, dann konstante und zum Ende der Lebenszeit durch eine steigende Fehlerrate auszeichnen.

Zu Beginn ist eine hohe, jedoch schnell abfallende Fehlerrate zu verzeichnen. Diese als frühe Ausfälle, auch Säuglingssterblichkeit (engl. *infant mortality*), bezeichneten Fehler sind auf Schwankungen und Fehler während der Herstellung zurückzuführen. Im Zusammenhang der integrierten Schaltungen handelt es sich hierbei um durch den Herstellungsprozess hervorgerufene Prozessvariationen. Diese rufen eine statistische Verteilung der einzelnen Prozessparameter hervor und können dazu führen, dass einzelne Schaltungen fehlerhaft sind bzw. außerhalb der Spezifikationen liegen, wie in Abbildung 2.2 gezeigt. Durch sogenannte *Burn-in* Tests bei teilweise erhöhten Stressbedingungen für Temperatur und Spannungen können sehr anfällige Schaltungen bereits zu Beginn aussortiert und die Fehlerrate gesenkt werden. Der Anteil funktionstüchtiger Systeme nach der Produktion wird auch als funktionale Ausbeute bzw. *functional Yield* bezeichnet. Der nach den initialen Tests verbleibende Anteil an funktionsfähigen Systemen, welche die Spezifikationen erfüllen, ist als parametrische Ausbeute bzw. *parametric Yield* definiert [MS06].

Während der Nutzungsdauer treten unvorhersehbare zufällige Fehler auf, was zu einer annähernd konstanten Fehlerrate führt.

Zum Ende der Lebenszeit kommt es zu Verschleißerscheinungen, welche einen Anstieg der Fehlerrate hervorrufen. Dabei handelt es sich unter anderem um Alterungsmechanismen in integrierten Schaltungen, die eine Veränderung der Schaltungseigenschaften über der Betriebszeit verursachen, bis die Spezifikationen verletzt werden oder die Schaltung gänzlich versagt.

Die einzelnen für die Zuverlässigkeit in CMOS Schaltungen relevanten Mechanismen werden im Folgenden näher erläutert.

Neben dem Begriff der Zuverlässigkeit existieren noch weitere Bezeichnungen, welche den Umgang eines Systems mit sich verändernden Umgebungs- oder Lastbedingungen bezeichnen. Dazu zählt zum einen die sog. Robustheit (engl. *robustness*), welche die Fähigkeit eines Systems beschreibt, einer Veränderung der Bedingungen ohne Anpassung zu widerstehen. Im Gegensatz dazu beschreibt die Resilienz (engl. *resilience*) die Fähigkeit eines Systems, durch bspw.




Abbildung 2.2.: Darstellung einer normalverteilten Schaltungseigenschaft P mit Spezifikationsgrenzen (rot) und den entsprechenden Fehlerbereichen (schraffiert).

adaptive Anpassung auf veränderliche Einflüsse zu reagieren und somit die Systemfunktion aufrechtzuerhalten.

2.1.1. Systemzuverlässigkeit

Ein System lässt sich in der Regel in mehrere Subsysteme unterteilen. Die Zuverlässigkeitseinflüsse können sich auf verschiedene Teile oder Teilschaltungen eines Systems in unterschiedlicher Weise auswirken und das Verhalten anderer Komponenten beeinflussen. Daher muss die resultierende Zuverlässigkeitsbewertung diese Abhängigkeiten berücksichtigen.

Für die Zuverlässigkeitsbewertung eines Gesamtsystems bestehend aus mehreren Subsystemen ist die Kombination der Teilsysteme entscheidend. Wenn diese parallel geschaltet sind, ist die Systemzuverlässigkeit R_{sys} gegeben durch [Mye10]:

$$R_{sys} = 1 - \prod_{i=1}^N (1 - R_i) \quad (2.3)$$

Dabei ist N die Anzahl der parallelen Teilschaltungen und R_i die Zuverlässigkeit des i -ten Teilsystems. Die Ausfallrate ist gegeben durch $F_i = 1 - R_i$. Für ein serielles System ergibt sich die Systemzuverlässigkeit zu

$$R_{sys} = \prod_{i=1}^N R_i. \quad (2.4)$$

Die Unterscheidung zwischen parallelen oder seriellen Teilsystemen geschieht aus systemtheoretischer Sichtweise im Bezug auf die betrachteten Eigenschaften und ist daher nicht immer mit der Art der elektrischen Verschaltung der Subsysteme identisch. Wird bspw. die Gesamtleistungsaufnahme betrachtet, werden die Leistungsaufnahmen der Teilsysteme als parallel behandelt. Bei hintereinander geschalteten Verstärkern wird die Gesamtverstärkung seriell bestimmt, wodurch sich auch die Systemzuverlässigkeit seriell aus den Zuverlässigkeiten der




Abbildung 2.3.: Aufbau eines planaren n-Kanal-MOSFETs [Raz12].

einzelnen Verstärker zusammensetzt. Für jede betrachtete Schaltungseigenschaft muss der Typ individuell bestimmt werden.

Der Stichprobenumfang ist entscheidend für die Aussagefähigkeit über die Zuverlässigkeit. Ist der Umfang der verwendeten Stichprobe zu klein, können nicht genügend Informationen gewonnen und keine aussagekräftigen Schlussfolgerungen gezogen werden. Dies kann zu einer Fehleinschätzung der Zuverlässigkeit führen. Methoden zur Bestimmung des Stichprobenumfangs werden beispielsweise in [GGP15] beschrieben.

2.2. Zuverlässigkeit in integrierten Schaltungen

In diesem Abschnitt werden die verschiedenen in dieser Arbeit berücksichtigten Zuverlässigkeitseinflüsse beschrieben, welche Auswirkungen auf die Funktionalität und das Verhalten integrierter Schaltungen haben. Diese Einflüsse werden unter dem Begriff PVTa zusammengefasst: **P**rozessvariation, **V** spannungs- (**V**) und **T**emperaturschwankungen sowie **A**lterung.

Transistoren stellen eines der grundlegenden Bauelemente integrierter Schaltungen dar. Die fortschreitende Verkleinerung der Strukturgrößen in modernen CMOS-Prozessen (*Complementary Metal-Oxide-Semiconductor* (CMOS)) führt dazu, dass die Zuverlässigkeitseffekte einen größeren Einfluss auf das Verhalten der Bauelemente haben. Der grundlegende Aufbau eines planaren Metalloxid-Halbleiter Feldeffekttransistors (MOSFETs) ist in Abbildung 2.3 gezeigt. Der hier dargestellte n-Kanal MOSFET ist in einem p-dotierten Substrat aufgebaut. Die Diffusionsgebiete unter dem Source- und Drainkontakt sind n-leitend dotiert. Die Dimensionen des Transistors werden über die Länge L und Weite W des Gates definiert. Die tatsächliche sog. effektive Länge L_{eff} des Kanals ist etwas geringer, da die Diffusionsgebiete des Source- und Drainkontakts etwas unter das Gate reichen: $L = L_{\text{eff}} + 2L_D$. Die Dicke der Oxidschicht wird als Oxiddicke t_{OX} bezeichnet und hat neben den Dimensionen einen signifikanten Einfluss auf die Charakteristik des MOSFETs. Die Stapelung von Bulk, Dielektrikum und Gate bildet einen Kondensator, über dessen elektrisches Feld die Strom-Spannungs-Charakteristik des Transistors gesteuert werden kann. Die Charakteristik moderner MOSFETs ist komplex, die grundlegende Funktionalität

kann jedoch durch die vereinfachte Betrachtung des quadratischen Modells erläutert werden. Abhängig von den angelegten Spannungen wird zwischen drei Betriebsbereichen unterschieden:

- Subschwelligbereich/schwache Inversion: $V_{GS} < V_{th}$
- Linearer Bereich/Triodenbereich: $V_{GS} > V_{th}$ und $V_{DS} < (V_{GS} - V_{th})$
- Sättigung/starke Inversion: $V_{GS} > V_{th}$ und $V_{DS} > (V_{GS} - V_{th})$

Beim Anlegen einer positiven Spannung V_{GS} kommt es zu einer Verarmung unterhalb des Gateoxids, die Majoritätsträger werden verdrängt. Wird V_{GS} weiter über die Schwellspannung V_{th} hinaus erhöht, bildet sich unterhalb des Gates ein Inversionskanal. Die Majoritätsträger wurden komplett verdrängt und es kommt zu einer Ansammlung von, im Fall des hier betrachteten n-Kanal MOSFET, negativ geladenen Minoritätsträgern. Beim Erreichen der Sättigungsspannung $V_{DS,sat} = V_{GS} - V_{th}$ kommt es zum Abschnüren des Kanals. Eine weitere Erhöhung von V_{GS} führt zu einer Verschiebung des Abschnürpunktes in Richtung Source-Kontakt, da die negative Kanalladung vom elektrischen Feld des Drain-Kontakts verdrängt wird. In diesem Bereich kommt es lediglich zu einer geringen Erhöhung des Drainstroms aufgrund von Kanallängenmodulation.

Neben diesen MOSFETs in konventioneller Bulk-Planarbauweise, werden in dieser Arbeit auch FDSOI-Transistoren in Beispielschaltungen verwendet. Bei *Fully-Depleted Silicon On Insulator* (FDSOI) handelt es sich um einen Fertigungsprozess, bei dem sich unter dem Kanal-Silizium eine dünne isolierende Schicht befindet (vergrabene Oxidschicht, *buried-oxide*), welche den Kanal isoliert [STM23]. Diese Technik zeichnet sich durch eine gute elektrostatische Steuerbarkeit aus, geringere Versorgungsspannungen und parasitäre Kapazitäten bei reduzierten Leckströmen sowie eine inhärent höhere Toleranz gegenüber Strahlungseffekten.

2.2.1. Prozessvariation

Als Prozessvariation oder auch *Time Zero Variability* (TZV) werden Abweichungen bezeichnet, die während des Herstellungsprozesses integrierter Schaltungen auftreten. Dabei sind Transistorparameter wie Länge L und Weite W , Oxiddicke t_{OX} und Dotierkonzentrationen betroffen. Prozessvariation kann dazu führen, dass Schaltungen zwar funktionieren, ihre Eigenschaften sich aber außerhalb der Spezifikationen befinden und sie daher Ausschuss sind. Bei der Prozessvariation wird zwischen lokaler (*intra-die*) und globaler (*inter-die*) Variation unterschieden [EM13]. Lokale Variation beschreibt die Unterschiede zwischen eigentlich identisch designten Transistoren, welche aufgrund von Prozessvariation unterschiedliche Parameter und damit abweichendes Verhalten aufweisen. Dies wird auch als *device mismatch* bezeichnet. Dabei ist die örtliche Entfernung dieser Transistoren meist gering, sie befinden sich innerhalb einer Schaltung. Als globale Variation werden Veränderungen zwischen einzelnen Chips, Wafern oder sogar Lots bezeichnet. Diese zeichnen sich durch eine Veränderung des Mittelwerts eines Parameters, bspw. der Länge oder der Dotierkonzentration, aus. Im Verlauf dieser Arbeit werden insbesondere die lokalen Variationen betrachtet, welche noch einmal in systematische und zufällige Abweichungen unterteilt werden können. Systematische Fehler passieren aufgrund von prozessbedingten Gegebenheiten, sodass diese durch spezielle Layout-Techniken

und Verbesserungen im Herstellungsprozess möglichst gering gehalten werden. Die zufälligen Fehler hingegen, welche im Folgenden näher erläutert werden, können nicht durch derartige Techniken beeinflusst werden, sondern müssen im Designprozess berücksichtigt werden, um die Funktionalität der Schaltung sicherzustellen. Bei kleineren Technologieknoten nehmen die Anzahl der Einflüsse sowie deren Auswirkungen zu [KKK⁺08]. Hier erfolgt eine kurze Beschreibung der wichtigsten Effekte für Technologien kleiner 90nm.

Random Dopant Fluctuation (RDF) Die Variation in der Anzahl und Position der Dotieratome verursacht eine Veränderung der Schwellspannung [KKK⁺08]. Bei sinkender Strukturgröße in kleinen Technologien und damit einhergehender geringerer Anzahl an Dotieratomen steigt der Einfluss dieses Effekts. Die Standardabweichung der Schwellspannung durch RDF kann beschrieben werden durch [SWK98]:

$$\sigma_{V_{th}} = \frac{\sqrt[4]{4q^3 \epsilon_{si} \phi_b}}{2} \cdot \frac{t_{OX}}{\epsilon_{ox}} \cdot \frac{\sqrt[4]{N_b}}{\sqrt{W_{eff} \cdot L_{eff}}} \quad (2.5)$$

Aus dieser Formulierung wird auch deutlich, dass die Veränderung anderer Prozessparameter wie der Oxiddicke t_{OX} oder der Kanaldotierung N mit der RDF wechselwirken.

Line-edge- und Line-width-Roughness (LER/LWR) tritt an den Kanten des Gate-Kontakts eines Transistors auf, wenn dieses aus Poly-Silizium gefertigt ist. Dabei weicht die tatsächliche Struktur (Länge und Weite des Transistors) aufgrund von Variationen während des Lithographie-Prozesses von der idealen Form ab [AKB03]. Dies führt zu einer Veränderung der Schwellspannung sowie einem Anstieg des Leckstroms. Auch dieser Effekt zeigt bei kleineren Technologieknoten größeren Einfluss, da die Ungenauigkeiten der LER/LWR nicht skalieren und somit in Relation zur Strukturgröße zunehmen.

Des Weiteren existieren Effekte, welche das Dielektrikum betreffen. Die Oxidschicht wird während der Prozessierung durch Aufwachsen gebildet und unterliegt daher auch Schwankungen. Insbesondere wenn die **Oxiddicke** t_{OX} lediglich wenige Atomlagen dick ist, fallen Höhenunterschiede stark ins Gewicht. Dabei treten Variationen sowohl innerhalb der Gate-Oxidschicht eines Transistors als auch zwischen verschiedenen Transistoren auf und beeinflussen die Ladungsträgerbeweglichkeit, den Gate Tunnel-Strom sowie die Schwellspannung [AKD02]. Die Anwesenheit fester Ladungsträger (**Fixed Charge**) im Gate-Dielektrikum kann ebenfalls zu einer Veränderung der Ladungsträgermobilität sowie einer Störung der Gleichmäßigkeit und Instabilität der Schwellspannung führen [KKK⁺08]. Gleiches gilt beim Auftreten von Defekten oder Ladungsträgerfallen (**Defects and Traps**).

2.2.2. Spannung und Temperatur

Die grundlegende Funktionalität eines MOS-Transistors basiert auf der Abhängigkeit seines Verhaltens von den an seinen Kontakten anliegenden Spannungen. Daher können Schwan-

kungen der Versorgungsspannung zu starken Variationen des Schaltungsverhaltens führen. Die Abhängigkeit von der Spannung lässt sich über die Abhängigkeit des Drainstroms mithilfe des quadratischen Modells zeigen. Nachfolgend sind die Gleichungen für verschiedene Inversionsbereiche gezeigt:

Subschwelligbereich:

$$I_{DS} = I_{DS,0} \cdot e^{\frac{V_{GS} - V_{th}}{kT}} \quad (2.6)$$

Linearer Bereich:

$$I_{DS} = \mu C_{OX} \frac{W}{L} \left((V_{GS} - V_{th}) V_{DS} - \frac{V_{DS}^2}{2} \right) \quad (2.7)$$

Sättigungsbereich:

$$I_{DS} = \frac{1}{2} \mu C_{OX} \frac{W}{L} (V_{GS} - V_{th})^2 (1 + \lambda V_{DS}) \quad (2.8)$$

Die am Transistor anliegenden Spannungen werden maßgeblich durch die Versorgungsspannung bestimmt. Eine Veränderung der Versorgungsspannung kann somit, bei fehlenden Gegenmaßnahmen, eine Veränderung der Spannungen an den Anschlüssen der einzelnen Transistoren nach sich ziehen, wodurch sich der Drainstrom entsprechend der oben gezeigten Gleichungen verändert.

Das Verhalten eines MOS-Transistors ist zudem stark von der Temperatur abhängig. Temperaturänderungen können zum einen durch die äußeren Gegebenheiten und Betriebsbedingungen entstehen, zum anderen kann es aufgrund von jouleschen Verlusten zu einer Selbsterwärmung der Schaltung während des Betriebs kommen. Die Eigenschaften von Halbleitern an sich weisen eine starke Temperaturabhängigkeit auf, ihre Leitfähigkeit steigt mit zunehmender Temperatur exponentiell. Dies ist begründet in den Temperaturabhängigkeiten der Ladungsträgerkonzentrationen sowie der Beweglichkeit [ITvM07, Bak10]. Die Mobilität nimmt über die Temperatur ab, dies wird empirisch modelliert über:

$$\mu(T) = \mu(T_0) \cdot \left(\frac{T_0}{T} \right)^{a_n} \quad (2.9)$$

wobei der Faktor a_n zwischen 1,5 und 2 liegt [Hof09]. Die intrinsische Ladungsträgerkonzentration ist folgendermaßen von der Temperatur abhängig:

$$n_i = \sqrt{N_C N_V} e^{\frac{-W_g(T)}{2kT}} \quad (2.10)$$

wobei N_C/N_V die äquivalenten Zustandsdichten und W_g der Bandabstand sind. Die damit einhergehende Temperaturabhängigkeit des Fermipotentials [Hof09] ist gegeben durch

$$\phi_F = \frac{kT}{q} \ln \left(\frac{N_A}{n_i} \right) \quad (2.11)$$

Aufgrund dieser Abhängigkeiten variieren quasi alle Parameter des MOS-Transistors mit der Temperatur. In den Transistormodellen wird diese Temperaturabhängigkeit durch die Veränderung der Schwellspannung V_{th} (bei schwellspannungsbasierten Modellen) sowie der




Abbildung 2.4.: Temperaturverhalten des Drainstroms für einen Transistor in STM 28nm Technologie mit $L = 60$ nm und $W = 120$ nm.

Ladungsträgermobilität μ modelliert [Bak10]. Der Temperaturkoeffizient der Schwellspannung ergibt sich zu

$$TCV_{thn} = \frac{1}{V_{th}} \cdot \frac{\partial V_{thn}}{\partial T} \quad . \quad (2.12)$$

Die Schwellspannung kann damit als Funktion der Temperatur T definiert werden:

$$V_{th}(T) = V_{th}(T_0) \cdot (1 + TCV_{thn} \cdot (T - T_0)) \quad . \quad (2.13)$$

Der Temperaturkoeffizient TCV_{thn} ist negativ, sodass die Schwellspannung bei steigender Temperatur sinkt.

Befindet sich der Transistor in Sättigung, sorgt die Verringerung der Mobilität bei steigender Temperatur für eine Abnahme des Drainstroms I_D während die sinkende Schwellspannung eine Zunahme von I_D hervorruft. Die daraus resultierende Abhängigkeit des Drainstroms von der Temperatur ist beispielhaft in Abbildung 2.4 für einen Transistor in 28nm FDSOI Technologie gezeigt.

Bei kleinen Gatespannungen V_{GS} überwiegt der Einfluss der Schwellspannungsänderung, während bei höheren V_{GS} die Veränderung der Mobilität der dominante Effekt ist. Dazwischen gibt es einen kleinen Spannungsbereich in dem sich die Effekte aufheben und der Drainstrom damit temperaturunabhängig ist. Der Einfluss von V_{DS} ist hier vernachlässigbar klein.

2.2.3. Alterung

Als Alterung oder *Time Dependent Variability* (TDV) wird die Veränderung von Transistorparametern über die Betriebszeit bezeichnet, welche eine Abweichung der Schaltungseigenschaften nach sich ziehen kann. Dabei wird zwischen Mechanismen unterschieden, die

entweder zu einer graduellen oder einer abrupten Degradation des Transistors und seiner Parameter führen. Eine plötzliche Fehlfunktion kann beispielsweise durch *Time Dependent Dielectric Breakdown* (TDDB) hervorgerufen werden, wobei es zu einer leitenden Verbindung durch das eigentlich isolierende Gateoxid kommt [EM13]. Die zunächst schleichende Degradierung des Dielektrikums führt damit im Moment des Durchbruchs zu einem Ausfall des betroffenen Transistors. Ein weiterer Effekt, der zu einem plötzlichen Ausfall führen kann, ist die Elektromigration (EM) [SWV⁺09]. Diese betrifft nicht die Transistoren an sich, sondern die Verbindungsleitungen und verursacht dort einen Materialtransport der Ionen des Leiters, hervorgerufen durch den Impuls der Leitungselektronen. Insbesondere bei hohen Stromdichten kann dieses Abtragen von Leiterbahn-Metall zu einer Unterbrechung der Verbindung führen.

Im Gegensatz zu diesen plötzlich auftretenden Effekten existieren Mechanismen, welche zu einer graduellen Veränderung der Transistoreigenschaften und damit des Schaltungsverhaltens über der Zeit führen. Die beiden maßgeblichen Effekte sind dabei *Hot Carrier Injection* (HCI) [Gra14, EM13] bzw. *Hot Carrier Degradation* (HCD) sowie *Bias Temperature Instability* (BTI) [Gra13, EM13], welche im Rahmen dieser Arbeit betrachtet werden. Beide basieren auf der Anhäufung zusätzlicher Ladungsträger, was zu einer Veränderung der Transistorparameter führt. Zudem weisen beide Effekte eine starke Abhängigkeit von verschiedenen Umgebungs- und Betriebsparametern wie der Temperatur (hier insbesondere BTI) sowie den Stressbedingungen auf, also den Spannungen an den Kontakten eines jeden Transistors sowie deren zeitlicher Verlauf. Darüber hinaus beeinflussen die Transistorparameter, welche auch Prozessvariation unterliegen, das Degradationsverhalten maßgeblich, sodass Transistoren in unterschiedlichen Prozessecken eine abweichende Stärke der Degradation aufweisen. Beide Alterungseffekte sind schon lange bekannt, BTI wurde bereit in den 1960er Jahren entdeckt [EM13]. Die genauen physikalischen Prozesse der Mechanismen werden nach wie vor erforscht, auch da mit neuen Herstellungstechnologien und moderneren Messverfahren fortwährend neue Effekte entdeckt und modelliert werden können. Die nachfolgende Beschreibung bezieht sich daher auf die für die in dieser Arbeit verwendeten Alterungsmodelle.

HCI beruht auf dem Auftreten von Ladungsträgern mit hoher kinetischer Energie aufgrund des starken lateralen elektrischen Feld im Kanal eines Transistors, sog. heiße Ladungsträger (engl. *hot carrier*) [EM13]. Dabei sind die höchsten kinetischen Energien in der Drain-Region zu beobachten, aufgrund der Beschleunigung der Ladungsträger vom Source-Kontakt in Richtung des Drain-Kontakts. Einige dieser Ladungsträger erreichen eine so hohe kinetische Energie, dass sie bei einem Zusammenstoß mit Gitteratomen die Bindung zerstören können. Kommt es nach der Zerstörung der Bindung zu einer Relaxation, so ist die Zerstörung irreversibel, was zur Bildung eines Dangling Bonds führt. Dabei handelt es sich um nicht abgesättigte Bindungen, welche in der Folge als Ladungsträgerfallen fungieren können. Die Bindungsenergie ist dabei entscheidend für diesen Effekt. Je geringer die Bindungsenergie, desto anfälliger ist diese Bindung und desto wahrscheinlicher ist deren Zerstörung durch einen energiereichen Ladungsträger. Schwächere Bindungen treten vor allem an der Grenzschicht zum Gateoxid auf. Aufgrund der unterschiedlichen Kristallstrukturen von Silizium und Siliziumdioxid existieren an der Grenzschicht beider Materialien Dangling Bonds, welche während des Herstellungsprozesses mit Wasserstoff passiviert werden, um die Anzahl zusätzlicher möglicher Zustände in der

Bandlücke zu reduzieren. Die Bindungsenergie von Silizium zu Wasserstoff ist jedoch geringer als eine Silizium-Silizium Bindung, sodass diese leichter durch energiereiche Ladungsträger zerstört werden kann.

Die mit HCI verbundene Ansammlung zusätzlicher Ladungen führt zu einer Verschiebung der Transistorparameter. Die durch HCI hervorgerufene Veränderung des Verhaltens wird auch als HCD bezeichnet. Aufgrund der höheren Ladungsträgerbeweglichkeit und den damit einhergehenden höheren kinetischen Energien, die innerhalb des Kanals erreicht werden können, tritt HCI vor allem in NMOS Transistoren auf.

In vielen industriell verwendeten Modellen sind lediglich vereinfachte Zusammenhänge modelliert [Gra14], um diese im Schaltungskontext simulierbar zu machen, während die genauen physikalischen Prozesse und damit einhergehende notwendige Modellierung noch aktuellen Forschungen unterliegt. Grundlegend kann bei HCI jedoch zwischen den folgenden Mechanismen unterschieden werden.

Einzelne Ladungsträger, die sogenannten heißen Elektronen oder *'lucky electrons'*, erreichen durch das starke laterale elektrische Feld im Kanal die nötige Energie, um bei einer Kollision mit einem Gitteratom eine Bindung zu zerstören. Dieser Effekt führt besonders bei älteren und größeren Technologien mit höheren Spannungen zur Degradation und bildet die Basis vieler Alterungsmodelle zur Schaltungsanalyse [Gra14]. In modernen kleineren Technologien lässt sich HCD jedoch nicht mehr ausschließlich durch diesen Effekt modellieren. Beim **Mehrfach-Ladungsträger**-Mechanismus wird die Zerstörung der Bindung nicht durch einen einzelnen energiereichen Ladungsträger hervorgerufen, sondern durch die wiederholte Kollision mit mehreren Ladungsträgern. Dabei ist die Energie der an der Kollision beteiligten Ladungsträger groß genug, damit eine Anregung in Zwischenenergieniveaus erfolgen kann. Bei der **Streuung von Ladungsträgern** wird durch die elastische Kollision zweier Ladungsträger im Kanal ein sehr energiereicher Ladungsträger erzeugt. Dieser besitzt genügend Energie zur Zerstörung einer Bindung, wenn es zur anschließenden Kollision mit einem Gitteratom kommt.

BTI basiert ebenfalls auf der Zerstörung von Bindungen und der damit einhergehenden Anreicherung zusätzlicher Ladungen [EM13, Gra13]. Im Gegensatz zu HCI ist dies jedoch nicht auf die Drain-Region beschränkt, sondern geschieht über die komplette Kanallänge. Aufgrund der negativen Spannung am Gate erfolgt eine Beschleunigung der Ladungsträger in Richtung des Gateoxids. Bei einer Kollision mit den Gitteratomen an der Grenzschicht zwischen Silizium und Gateoxid können bei ausreichender Energie Bindungen zerstört werden. Aufgrund von thermischer Ionisation entstehen zudem tiefer im Oxid gelegene Fehlstellen, welche ebenfalls durch die in Richtung des Gates beschleunigten Ladungsträger besetzt werden können und zu einer Erhöhung der Ladung des Gateoxids führen. Diese thermische Ionisation ist zudem ausschlaggebend für die namensgebende starke Temperaturabhängigkeit von BTI. Im Gegensatz zu HCI sind einige Komponenten von BTI wiederherstellbar (engl. *recovery effect*), sobald die Stressbedingungen relaxieren. Aufgrund der komplizierteren Modellierung sowie dem anhaltenden wissenschaftlichen Diskurs zu den zugrundeliegenden Mechanismen wird diese Ausheilung in vielen kommerziellen Alterungsmodellen nicht berücksichtigt.

Bei diesem Effekt erfolgt die Unterscheidung aufgrund der positiven oder negativen Gate-Spannung zwischen *Negative Bias Temperature Instability* (NBTI) bei PMOS-Transistoren und

Positive Bias Temperature Instability (PBTI) bei NMOS-Transistoren. In NMOS-Transistoren ist jedoch der HCI Effekt dominant, weshalb PBTI in der Literatur häufig vernachlässigt wird und auch in den meisten Alterungsmodellen nicht berücksichtigt wird.

2.3. Zuverlässigkeit im Entwurfsprozess integrierter Schaltungen

Mit der zunehmenden Bedeutung von Zuverlässigkeitsaspekten und deren Auswirkung insbesondere auf sicherheitskritische Systeme wächst das Interesse an Methoden, um diese möglichst frühzeitig im Entwurfsprozess berücksichtigen zu können.

Der Entwurf integrierter CMOS-Schaltungen stützt sich im Wesentlichen auf die Simulation des Schaltungsverhaltens mithilfe spezieller Schaltungssimulatoren. Dies beginnt mit dem Entwurf und der Simulation einzelner Teilschaltungen und endet in einer Simulation des gesamten Chips (*full-chip simulation*) inklusive der durch das Layout entstehenden parasitären Effekte (*post-layout simulation*). Im Vergleich zum Entwurf digitaler Schaltungen ist der Entwurfsprozess analoger Komponenten deutlich weniger automatisiert. Daher ist auch die Berücksichtigung von Zuverlässigkeitsaspekten bei der Dimensionierung von Analogkomponenten mit einem deutlich höheren Designaufwand verbunden.

Um das individuelle Verhalten der einzelnen Bauteile eines Prozesses simulieren zu können und damit den Entwurf zu ermöglichen, werden entsprechende Modelle und Simulatoren für die Simulationen benötigt. In der Vergangenheit wurden seit den 1980er Jahren zu diesem Zweck verschiedene Modelle entwickelt, die mit der Weiterentwicklung der Herstellungstechnologien und Strukturgrößen ebenfalls laufend weiterentwickelt wurden. Eines der am weitesten verbreiteten und als Industriestandard angenommenen Modelle ist das *Berkeley Short-channel IGFET Model* (BSIM). Dieses physikbasierte Modell bildet das Verhalten der Transistoren mithilfe zahlreicher empirisch ermittelter Parameter ab und hat den Anspruch, möglichst genau und skalierbar zu sein [UC 21]. Während ältere BSIM-Modelle für größere Prozessgrößen auf der Schwellspannung basieren und anhand dieser das Schaltverhalten ermitteln, handelt es sich bei den neuen Modellen der Generation BSIM6 um ladungsbasierte Modelle, welche die Effekte kleiner Technologien besser abbilden können. Zu den ladungsbasierten Modellen zählt auch das sog. EKV-Modell [EV06], welches den gesamten Betriebsbereich eines MOSFET inklusive des Subschwelligbereichs abbildet und dabei auf einer deutlich geringeren Anzahl an Parametern beruht. Mit dem neuartigen Modellansatz soll eine gute Genauigkeit in der Modellierung erreicht werden und, aufgrund der im Vergleich zu modernen BSIM-Modellen überschaubaren Anzahl an Parametern, eine händische Berechnung ermöglicht werden. Darüber hinaus existieren Modelle für spezielle Technologien, wie das ebenfalls ladungsbasierte UTSOI-Modell, welches bspw. für die FDSOI-Prozesse von STMicroelectronics zum Einsatz kommt [cL12].

Die Parameter und Modelle der Bauteile eines Prozesses werden von den Halbleiterherstellern im sog. *Process Design Kit* (PDK) zusammengefasst. Dieses stellt die benötigten Daten wie bspw. Bauteilmodelle, Prozessdaten und Layoutregeln für die einzelnen Schritte und Programme der Entwurfssoftware bereit [Mic17].

Für die Verifikation ist die Simulation der entwickelten analogen, digitalen sowie Mixed-Signal Schaltungen basierend auf den in einem PDK hinterlegten prozessspezifischen Bauteilmodellen notwendig. Die Simulation einer analogen Schaltung auf Transistorebene erfolgt mit Simulatoren wie *Simulation Program with Integrated Circuit Emphasis* (SPICE) [NP73] oder SPICE-ähnlichen Simulationsprogrammen wie bspw. Spectre von Cadence Design Systems [KG95, Cad], HSPICE (Synopsys) oder ELDO (Siemens EDA, ehem. Mentor Graphics). Einige Anwendungen erlauben zudem die Simulation von Modellen, welche in Verhaltensbeschreibungssprachen vorliegen, so ist in Spectre und HSPICE die Simulation von Verilog-A/MS bzw. VHDL-AMS möglich. Diese Art von Simulatoren sind speziell für die zeit- und wertkontinuierliche Analyse analoger Schaltungen bzw. der dafür benötigten Bauteilmodelle auf Transistorebene ausgelegt. Die Netzliste wird dabei in ein System aus linearen Differentialgleichungen übersetzt, deren Lösung mittels numerischer Methoden eine Reihe linearer Gleichungen ergibt, welche anschließend durch Matrixverfahren gelöst werden. Die Festlegung der Zeitschritte erfolgt dynamisch, sodass bei plötzlich auftretenden Änderungen der Signalpegel mehr Simulationspunkte gewählt werden. Die Simulation in SPICE ist sehr rechenintensiv. Die Komplexität steigt exponentiell mit der Anzahl an Bauteilen und Zeitschritten. Um die Simulation insbesondere größerer Systeme zu beschleunigen, existieren Erweiterungen der traditionellen SPICE-Simulatoren. Zum einen können in modernen Multikernprozessoren oder verteilten Rechnernetzen parallele Simulationen durchgeführt werden, wobei der durch die Parallelisierung hervorgerufene Overhead beachtet werden muss. Darüber hinaus ermöglichen Anwendungen wie FastSPICE den Umgang mit sehr großen Schaltungen durch die Aufteilung der zu lösenden Matrizen und Verwendung von vorberechneten Bauteilparametern aus *Look-Up Table* (LUT)s. Die damit einhergehende geringere Genauigkeit muss dabei abgewogen werden, insbesondere bei Kopplungen innerhalb der Schaltung [Mic17].

Im Gegensatz zur Analyse analoger Schaltungen erfolgt die Simulation rein digitaler Schaltungen zeit- und wertdiskret, da hier lediglich die Zustände sowie das Timing von Interesse sind. Der Zusammenhang zwischen Simulationszeit und Anzahl der Bauteile ist bei diesen Event-basierten Simulatoren linear. Für die Simulation eines Mixed-Signal-Systems ist meist die Kopplung eines analogen mit einem digitalen Simulator nötig.

2.3.1. Monte-Carlo- und Corner-Simulation

Im Entwurfsprozess integrierter Schaltungen werden vorrangig zwei Möglichkeiten verwendet, um Prozessvariation in der Schaltungssimulation zu berücksichtigen: Monte-Carlo- und Corner-Simulationen (Prozessecken-Simulation). Diese unterscheiden sich wesentlich in der Art der berücksichtigten Variation sowie der benötigten Anzahl an Einzelsimulationen.

Bei der Corner Simulation werden feste Prozessecken verwendet, um die möglichen Extrempunkte (Worst Cases) des Schaltungsverhaltens zu simulieren. Dabei stehen als Kombinationen zur Auswahl: nominelle Eigenschaften für PMOS und NMOS (*typical-typical*), schneller NMOS/PMOS bei langsamen PMOS/NMOS (*fast-slow*), langsamer PMOS und NMOS (*slow-slow*) sowie schnelle PMOS und NMOS (*fast-fast*) [Bak10, Hof09]. Diese Extrempunkte werden während eines regulären Herstellungsprozesses nicht erreicht, sodass deren Simulation keine Abbildung der wirklich zu erwartenden Variation der Schaltungseigenschaften ergibt. Sie dienen zur Ermittlung

von Extrembedingungen, um sicherzustellen, dass eine innerhalb dieser Prozessecken entworfene Schaltung mit einer sehr hohen Wahrscheinlichkeit auch funktionsfähig ist. Zusätzlich zu den einzelnen Prozessecken ist eine Simulation bei verschiedenen Temperaturen und Spannungen sinnvoll (PVT-Analyse), welche auch als Corner bezeichnet werden. Die Corner-Simulation findet vor allem im digitalen Entwurf Anwendung. Für die einzelnen Komponenten und Gatter sind im von Digitalsimulatoren genutzten *Liberty Format* einzelne Modelcards für jeden Corner vorhanden.

Im Gegensatz zur Corner Simulation wird bei der Monte-Carlo-Simulation (MC-Simulation) eine zufällige Variation von Prozess- und Mismatch-Parametern simuliert, sodass die statistische Verteilung der Schaltungseigenschaften untersucht werden kann. Dazu wird für jede Einzelsimulation eine zufällige Kombination an Parametern entsprechend der im PDK hinterlegten Prozessinformationen generiert. Je nach Implementierung des PDK können globale und lokale Variationen entweder einzeln oder gemeinsam betrachtet werden. Ein Nachteil der Monte-Carlo Simulation ist die Notwendigkeit einer großen Anzahl an Simulationen, um eine stichhaltige Aussage über die statistische Verteilung liefern zu können. Die Simulatoren stellen teilweise unterschiedliche Methoden zur Generation der zufälligen Parametervariationen bereit, bspw. (Pseudo-)Zufallsstichproben (engl. *pseudo-random*), *Latin Hypercube Sampling* (LHS) oder *Low Discrepancy Sampling*. Zufallsstichproben ist die meist verwendete Methode für Monte-Carlo-Stichproben, da diese die tatsächlichen physikalischen Prozesse nachbilden kann, durch welche die Variationen verursacht werden. Allerdings benötigt die Stichprobe einen großen Umfang, um hinreichend genaue Ergebnisse zu produzieren ($1/\sqrt{N}$), was viele mitunter zeitaufwendige Simulationen bedeutet. Daher wurden andere Stichprobenverfahren entwickelt, welche die Effizienz der Monte-Carlo-Analyse durch eine gleichmäßigere Auswahl von Stichprobenpunkten verbessern sollen. Neben der Latin Hypercube Methode steht bspw. in der Cadence Virtuoso Design Umgebung die *Low Discrepancy Sequence* Methode zur Auswahl [Cad18b]. Latin Hypercube ist ein quasi-zufälliger Stichprobenalgorithmus mit Stichprobenauswahl und -verwerfung. Der Stichprobenraum wird gleichmäßig in Unterräume aufgeteilt und die Stichprobenpunkte werden gleichzeitig ausgewählt, sodass jeder Unterraum mit der gleichen Dichte abgetastet wird. Der Latin-Hypercube-Algorithmus hat eine Konvergenzgenauigkeit von $1/N^{2/3}$. Bei der *Low Discrepancy Sequence* (LDS) wird eine deterministische Sequenz verwendet, um eine gleichmäßige Abdeckung des Sampling-Raums zu erhalten. Die Konvergenzgeschwindigkeit für LDS ist höher als bei der Zufallsstichprobe und ist vergleichbar mit der LHS-Methode, bietet jedoch im Gegensatz zu LHS die Möglichkeit, eine Auto-Stop Funktion zu verwenden, sobald die gewünschte Genauigkeit mit den bereits simulierten Samples erreicht wurde [Cad18b].

2.3.2. Alterungssimulation

Die Auswirkungen von Alterung auf das Verhalten einer Schaltung wird in der Regel nicht in den grundlegenden Transistormodellen wie den BSIM-Modellen beschrieben. Für die Analyse der Degradierung sind zusätzliche Berechnungen nötig, welche zusätzlich zu der eigentlichen Schaltungssimulation in SPICE durchgeführt werden müssen und darüber hinaus Informationen über die Alterung der einzelnen Transistoren benötigen. In den meisten Fällen wird dazu zusätzliche dedizierte Software eingesetzt, welche die nötigen Berechnungen zur Ermittlung

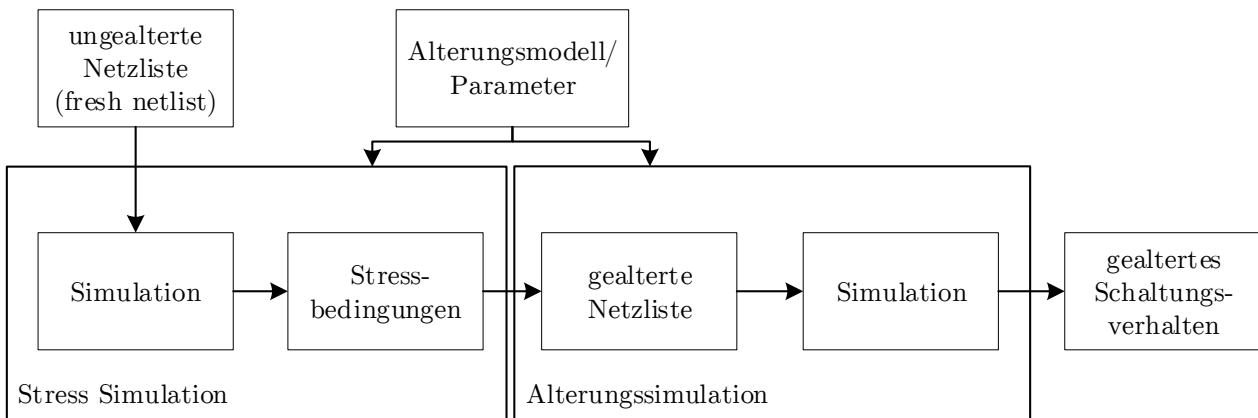


Abbildung 2.5.: Allgemeiner Ablauf einer Alterungssimulation nach [Gra14, TRC⁺93]

des Alterungszustands durchführt und die Ergebnisse an den Schaltungssimulator (SPICE) übergibt, sodass das gealterte Schaltungsverhalten simuliert werden kann.

In der Literatur sind die Entwicklungen einiger kommerzieller und nicht-kommerzieller Alterungssimulatoren nachzuvollziehen. Durch die zunehmende Bedeutung von Alterung sind diese heute generell in den kommerziell erhältlichen Simulationstools integriert. Jedoch enthalten nicht alle PDKs vom Hersteller bereitgestellte Alterungsmodelle. Der generelle Ablauf der Alterungssimulation kann verallgemeinert dargestellt werden, da er in den hier betrachteten Implementierungen auf den selben Prinzipien beruht. Einer der ersten veröffentlichten umfassenden Alterungssimulatoren sind die sog. *Berkeley Reliability Tools* (BERT) [TRC⁺93]. Viele moderne Alterungssimulatoren basieren auf den dort verwendeten Modellierungen und Simulationsansätzen, so beispielsweise der *Cadence Reliability Simulator RelXpert* [EM13, Cad18a] oder der nativ in Spectre integrierte *Reliability Simulator* [Cad].

Die individuelle Alterung eines Transistors ist abhängig von den Stressbedingungen, denen er ausgesetzt ist. Diese setzen sich neben der Temperatur aus den Spannungen und Strömen sowie deren zeitlichen Verläufen zusammen und sind somit für jeden Transistor innerhalb einer Schaltung individuell abhängig von der Topologie und den betrachteten Eingangssignalen. Der Alterungssimulator benötigt neben der initialen Netzliste, der zu untersuchenden Schaltung und den Transistormodellen, zusätzlich zum verwendeten Prozess zugehörige Alterungsmodelle. Der Ablauf einer Alterungssimulation lässt sich anschließend in mehrere Schritte unterteilen, wie in Abbildung 2.5 gezeigt:

- Zur Ermittlung der individuellen Stresszustände bzw. Stressbedingungen jedes einzelnen Transistors in einer Schaltung ist zunächst eine transiente Simulation der initialen nicht-gealterten Netzliste (*fresh netlist*) nötig. Die sich aus den Spannungen und Strömen an den Bauteil-Terminals ergebenden Stresszustände werden dann für jedes Bauelement gespeichert.
- Nach Beendigung der transienten Simulation wird anhand der gespeicherten Stressbedingungen mithilfe des Alterungsmodells die Degradation jedes Transistors berechnet. Dabei wird eine gealterte Netzliste erstellt, welche die durch die Degradation veränderten Transistorparameter enthält.

- Um das gealterte Schaltungsverhalten zu ermitteln, ist eine erneute Simulation der Netzliste mit den gealterten Parametern notwendig. Dabei können zur Bestimmung verschiedener Performances sowohl weitere transiente Simulationen als auch AC- oder DC-Simulationen bspw. zur Analyse des Frequenzverhaltens durchgeführt werden.

Aufgrund der mehrfach durchzuführenden Simulationen und Zwischenspeicherung der Stressbedingungen ist der Zeitaufwand besonders bei größeren Schaltungen hoch. Viele Simulatoren bieten zudem die Möglichkeit, auch graduelle Alterung zu betrachten, d.h. der Zustand wird zu verschiedenen Zeitpunkten evaluiert und die Degradation von diesen zum jeweils nächsten Zeitpunkt berechnet.

Viele Simulatoren wie RelXpert sowie Spectre von Cadence ermöglichen eine komplett automatisierte Alterungssimulation. Werden für die Bestimmung der Schaltungsperformances weitere Simulationen als die transiente benötigt, werden diese automatisch mit der gealterten Netzliste durchgeführt. Der in Eldo integrierte Alterungssimulator von Siemens EDA (ehem. Mentor Graphics) bietet dies nicht, die einzelnen Simulationen müssen vom Nutzer einzeln gestartet und die jeweiligen Dateien mit den gespeicherten gealterten Parametern individuell angegeben werden. Im Verlauf dieser Arbeit wurde im Zuge der Entwicklung des ReSeMBled-Tools, welches in 3.5 beschrieben wird, eine Umgebung geschaffen, welche auch die Alterungssimulation mit Eldo automatisiert.

Prozessvariation und Alterung

Aufgrund des Zusammenhangs zwischen der jeweiligen Prozessvariation eines Transistors und seines Alterungsverhaltens, ist auch eine kombinierte Analyse von Prozessvariation und Alterung interessant. Die prozessbedingten Schwankungen geben bestimmten Transistorparametern, wie zuvor beschrieben, eine statistische Verteilung um ihre Nominalwerte direkt nach der Herstellung, während die zeitabhängige Degradation diese Parameter während der Lebensdauer zusätzlich verschiebt. Dabei muss unterschieden werden zwischen stochastischen Alterungsmodellen, welche die Degradierung an sich stochastisch modellieren, und einer kombinierten Monte-Carlo- und Alterungssimulation. Diese Art der Kombination von MC- und Alterungssimulation wurde lange Zeit nicht von kommerziellen Simulatoren wie RelXpert oder Eldo unterstützt. Seit einiger Zeit bietet der native Spectre Reliability Simulator die Möglichkeit, MC-Simulationen mit Alterungssimulationen zu kombinieren [Cad].

Generell existieren für die Kombination von Prozessvariation- und Alterungssimulation zwei Möglichkeiten [Hei15, Art18]:

Alterung + Monte-Carlo Bei dieser Simulation wird zunächst eine nominale Stresssimulation ohne Monte-Carlo durchgeführt. Ausgehend von diesem Degradationszustand wird eine Monte-Carlo Simulation durchgeführt. Damit ergeben sich insgesamt $1 + N$ Simulationen, eine Alterungssimulation und N Monte-Carlo Analysen.

Monte-Carlo + Alterung Die zweite Möglichkeit besteht darin, zunächst eine Monte-Carlo Simulation der ungealterten Schaltung durchzuführen und anschließend für jeden einzelnen MC-Punkt eine Alterungssimulation anzuschließen. Diese Kombination resultiert in $N + N$ Simulationen für die Simulation eines Alterungszeitpunktes und $N_{MC} \cdot N_{age}$

Simulationen für mehrere graduelle Alterungszeitpunkte, was einen bedeutend größeren Simulationsaufwand bedeutet.

Da der Grad der Degradation unter anderem maßgeblich von den individuellen Prozessparametern abhängt, ist insbesondere die zweite Simulationsart von Interesse, um die Veränderung der Zuverlässigkeit über die Lebenszeit zu betrachten.

In der Vergangenheit wurden, auch auf Grund der fehlenden Verfügbarkeit kommerzieller Lösungen, einige proprietäre Simulatoren vorgestellt, um diese kombinierte Zuverlässigkeitssimulationen durchführen zu können und den Simulationsaufwand gleichzeitig möglichst gering zu halten. Zu nennen sind hier unter anderem die Arbeiten von Gielen und Maricau [GM13, MG10]. Im Verlauf dieser Arbeit kommen zudem die in [HPPD18] vorgestellten ladungsbasierten Transistormodelle zum Einsatz, welche die Berücksichtigung der Alterung direkt in einer Simulation sowie die Kombination mit einer MC-Simulation ermöglichen. Diese Modelle sind zwar nicht optimiert auf geringe Simulationszeiten, ermöglichen aber die notwendigen Analysen für die in Kapitel 3.4 vorgestellten stochastischen Verhaltensmodellierungen unter Berücksichtigung der PVTA-Variationen.

2.4. Zusammenfassung

In diesem Kapitel wurden die Grundlagen der Zuverlässigkeit in Systemen und integrierten Schaltungen betrachtet. Dazu wurden zunächst die während des Herstellungsprozesses und des Betriebs auftretenden Effekte beschrieben, die Einfluss auf die Funktionalität integrierter Schaltungen haben. Dazu zählen Prozessvariation, (Versorgungs)spannungs- und Temperaturschwankungen sowie Alterung, was unter dem Begriff PVTA zusammengefasst wird. Anschließend wurde auf die Berücksichtigung dieser Effekte mittels Schaltungssimulationen während des Entwurfs eingegangen.

PVTA

Verhaltensmodellierung

Dieses Kapitel behandelt die in dieser Arbeit entwickelten Modellierungsmethoden zur Erstellung von RSM-basierten PVTA-Verhaltensmodellen für Schaltungskomponenten. Die Modellierung basiert auf der *Response Surface Methodology*, welche im ersten Abschnitt genauer beleuchtet wird. Dazu gehören auch Verfahren der statistischen Versuchsplanung sowie die Bestimmung der Modellgenauigkeit. Danach erfolgt die Vorstellung der in dieser Arbeit entwickelten Modellierungsmethoden zur Erstellung von RSM-basierten und stochastischen Verhaltensmodellen. Zuletzt wird ein Überblick über das zur automatisierten Modellerstellung entwickelte MATLAB-Tool ReSeMBleD gegeben.

3.1. Grundlagen der Schaltungsmodellierung

In diesem Abschnitt werden die Grundlagen der in dieser Arbeit verwendeten Modellierungsmethoden vorgestellt. Dabei wird zunächst auf die Unterscheidung zwischen Verhaltensmodellen und sog. Performancemodellen eingegangen. Anschließend werden die zur Erstellung der Regressionsmodelle verwendete Response Surface Methodology sowie Methoden der statistischen Versuchsplanung erläutert und auf die Bestimmung der Modellfehler in verschiedenen Phasen des Modellierungsprozesses eingegangen.

3.1.1. Verhaltens- und Performancemodelle

In dieser Arbeit wird zwischen Verhaltensmodellen und sog. Performancemodellen unterschieden, was grundlegend für die entwickelten Modellierungsmethoden ist. Auch wenn Verhaltensmodellierung in vielerlei Disziplinen zum Einsatz kommt, wird hier immer auf die Modellierung integrierter Schaltungen Bezug genommen.

Der Nutzen von Modellierungen und Abstraktion wird auch durch die Gegenüberstellung von Simulationsgenauigkeit und Simulationsgeschwindigkeit in Abbildung 3.1 deutlich. Eine Schaltungssimulation mit einem SPICE-Simulator auf Transistorebene liefert zwar genaue Ergebnisse, benötigt aber insbesondere bei größeren Topologien mitunter viel Zeit. Für die Verifikation einer einzelnen Schaltungskomponente ist diese Art der Simulation jedoch unerlässlich [KCG09]. Für Simulationen eines Gesamtsystems auf Chip-Level sind SPICE-Simulationen damit jedoch sehr rechen- und zeitintensiv. An dieser Stelle ermöglicht die Abstraktion mittels

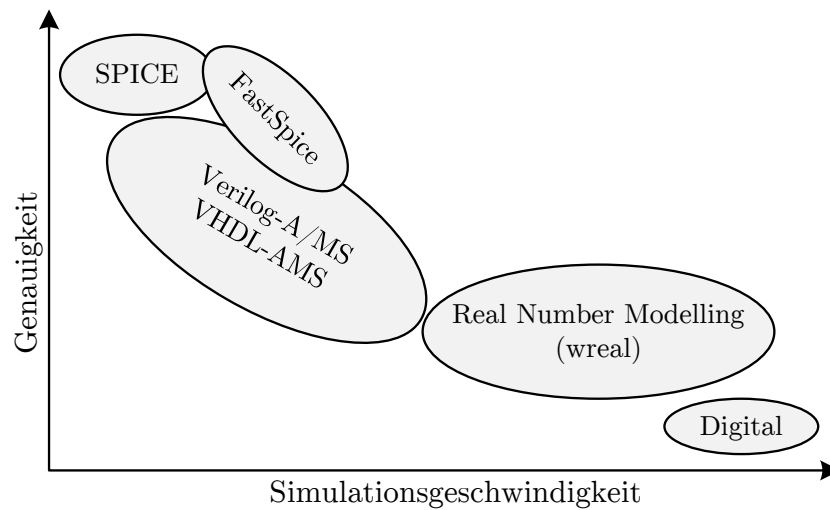


Abbildung 3.1.: Vergleich der Genauigkeit und Simulationsgeschwindigkeit verschiedener Modellierungs- und Abstraktionsebenen [KCG09]

Erstellung analoger Verhaltens- bzw. Performancemodelle eine signifikante Beschleunigung der Simulationszeit in Größenordnungen von 5 bis 100-fach [KCG09].

In Abbildung 3.1 zeigt sich, dass bei Verhaltensmodellen in Verilog-A/MS bzw. VHDL-AMS eine große Variation bzgl. Genauigkeit und Simulationsgeschwindigkeit möglich ist. Dies ist stark abhängig von der jeweiligen Anwendung sowie der benötigten Genauigkeit des Modells an sich. Während bei der reinen Verwendung von Verilog-A in der analogen Domäne mit Strömen und Spannungen modelliert wird, was die Lösung von Differentialgleichungen beinhaltet, ist mit der Erweiterung Verilog-A/MS auch die Modellierung digitaler Schaltungen möglich. Im Gegensatz zu der Modellierung in Verilog-A/MS handelt es sich bei dem *Real Number Model(ing)* (RNM) um ein reines Signalfuss-Modell. Die reine digitale Simulation auf Gatterebene stellt danach als weitere Abstraktionsebene die schnellste und ungenaueste Simulationsart in diesem Zusammenhang dar.

Verhaltensmodelle

Ein Verhaltensmodell (engl. *behavioral model*) bezeichnet im Bezug auf elektronische Schaltungen ein funktionales oder mathematisches Modell, welches das Verhalten einer Schaltungskomponente oder eines Systems nachbildet. Dabei wird grundlegend das Ein-Ausgangsverhalten an den Schnittstellen modelliert [DGS02]. Darüber hinaus kann aber auch die Abbildung weiterer Eigenschaften wie bspw. des Energieverbrauchs oder der internen Temperatur erfolgen, welche nicht direkt aus dem Klemmenverhalten extrahiert werden können. Verhaltensmodelle bieten grundsätzlich eine Möglichkeit zur Abstraktion und erlauben somit die Analyse des Verhaltens der modellierten Schaltung bspw. im Gesamtsystem-Kontext ohne die häufig zeitaufwendige Simulation auf Transistorebene.

Es existieren viele verschiedene Bezeichnungen für unterschiedliche Arten von Verhaltensmodellen, welche von einzelnen Autoren verwendet werden. Der Begriff Verhaltensmodell kann dabei

als übergeordnete Bezeichnung angesehen werden. Die Modellierung einzelner grundlegender Bauteile, wie etwa die BSIM Modelle für Transistoren, werden häufig als Kompaktmodellierung oder Bauteil-Modellierung (*device modeling*) bezeichnet. Das Modell einer Schaltung bestehend aus mehreren Bauelementen oder diversen Subsystemen wird dann Verhaltensmodell (*behavioral model*) oder auch *surrogate model* genannt. Grundlegend kann zwischen einer strukturellen Modellierung, bei welcher die einzelnen elektrischen Bauelemente einer Schaltung oder ein entsprechendes Ersatzschaltbild modelliert werden, und einer reinen funktionellen Modellierung durch eine algorithmische Beschreibung unterschieden werden.

Zur Modellierung analoger Schaltungskomponenten wurden entsprechende Verhaltensbeschreibungssprachen wie Verilog-A/MS und VHDL-AMS entwickelt, wobei es sich um Derivate ihrer entsprechenden digitalen Vorgänger handelt [KZ04]. Sie erlauben die Abbildung zeit- und wertkontinuierlicher Signale, sowie im Falle der Analog/Mixed-Signal- (AMS-) Varianten eine Kombination von analogen und digitalen Anteilen. Diese Beschreibungssprachen sind kompatibel mit vielen gängigen SPICE-class Simulatoren und erlauben somit auch eine gemeinsame Simulation von Verhaltensmodellen und Schaltungen, die auf Transistorebene vorliegen. Das Verhaltensmodell bildet in diesem Fall an seinen Klemmen die Strom-Spannung-Beziehungen ab. Darüber hinaus können Verhaltensmodelle zur weiteren Abstraktion auch außerhalb von Schaltungssimulationen erstellt werden, beispielsweise in MATLAB/Simulink. In diesem Fall sind meist einzelne Schaltungseigenschaften von Interesse, deren Modellierung im Folgenden beschrieben wird.

Bei einem elektronischen System S entsprechend Abbildung 3.2 welches das Ausgangsverhalten y hat, kann bei den Variablen zwischen Parametern \mathbf{i} , welche die Eingangssignale(e) charakterisieren, und Design- und Umgebungsparametern \mathbf{d} differenziert werden [DGS03]. Das Ausgangsverhalten ergibt sich damit zu

$$y = S(\mathbf{i}, \mathbf{d}). \quad (3.1)$$

Das Verhaltensmodell B bildet nun das Ein-Ausgangsverhalten des modellierten Systems S ab. In einem umfassenden Modell werden dabei die Abhängigkeiten aller Parameter berücksichtigt. Dies ist jedoch nicht immer notwendig, für viele Abstraktionen ist die Betrachtung einiger Parameter, welche das Verhalten maßgeblich beeinflussen, ausreichend

$$y = B(\mathbf{i}, \mathbf{d}). \quad (3.2)$$

Ein einfaches Beispiel für ein Verhaltensmodell einer analogen Schaltungskomponente ist das im Codebeispiel 3.1 gezeigte Modell eines idealen Verstärkers mit einer als festen Parameter definierten Verstärkung \mathbf{gain} . Hier zeigt sich, dass in einem derartigen Verhaltensmodell die charakteristischen Schaltungseigenschaften der zu modellierenden Schaltung als Parameter verwendet werden. Diese werden im Folgenden als Verhaltensmodellparameter (VM-Parameter) bezeichnet. Die Abhängigkeit dieser charakteristischen Schaltungseigenschaften von den Eingangs-, Design- und Umgebungsvariablen kann mit den nachfolgend erläuterten Performancemodellen abgebildet werden.

Listing 3.1: Einfaches Verilog-A-Verhaltensmodell eines idealen Verstärkers.

```

module amp(in , out);
input in;
output out;
    electrical in , out;

parameter real gain = 100;

    analog begin
        V(out) <+ gain*V(in);
    end
endmodule

```

Performancemodelle

Als Performancemodellierung (*performance modeling*) wird die Erstellung von Modellen für einzelne charakteristische Schaltungseigenschaften (*performances*) bezeichnet, welche das Ein-Ausgangsverhalten einer Schaltung oder eines Systems charakterisieren. Beispielhaft sind hier die Verstärkung und 3dB-Grenzfrequenz eines Verstärkers zu nennen. Da auf höherer Abstraktionsebene meist nicht sämtliche simulierbaren Eigenschaften einer Schaltungskomponente von Interesse sind, erfolgt lediglich die Modellierung der relevanten Eigenschaften, um den Modellierungsaufwand möglichst gering zu halten.

Aus dem Ein- Ausgangsverhalten des in Abbildung 3.2 gezeigten Systems S können die charakteristischen Eigenschaften \mathcal{P} bestimmt werden, welche ebenfalls von \mathbf{i} und \mathbf{d} abhängig sein können [DGS02, DGS03]

$$\mathcal{P} = g(\mathbf{i}, \mathbf{d}). \quad (3.3)$$

Ziel der Performancemodellierung ist es nun, den funktionalen Zusammenhang g zwischen den Parametern und den charakteristischen Eigenschaften durch eine geeignete Funktion f zu modellieren. Nicht jede Schaltungseigenschaften ist von jeweils allen Parametern oder dem Eingangssignal abhängig. Für jede Eigenschaft \mathcal{P}_k ergibt sich daher ein Parametersatz von m Modellparametern $\mathbf{p}_k = [p_{k1} \dots p_{km}]$, welche sich aus einer Teilmenge von (\mathbf{i}, \mathbf{d}) zusammensetzen

$$\mathcal{P}_k = f(\mathbf{p}_k). \quad (3.4)$$

Um ein alterungsabhängiges Performancemodell zu erstellen, wird das Alter t_{age} als zusätzlicher Modellparameter betrachtet.

$$\mathcal{P}_k = f(\mathbf{p}_k, t_{\text{age}}). \quad (3.5)$$

Für die Modellierung ist eine Identifizierung dieser Modellparameter ratsam, da die Berücksichtigung aller möglichen Parameter zu unnötig komplexen und aufwendigen Modellen mit einer eventuell schlechteren Modellgenauigkeit führt.

Performancemodelle können auf unterschiedliche Weise erstellt werden. Zum einen gibt es mathematische Modelle, welche die physikalischen Zusammenhänge einer bestimmten Schal-




Abbildung 3.2.: Darstellung eines elektrischen Systems S und allgemein und beispielhaft als Verstärker mit den zugehörigen Ein-/Ausgängen und Parametern [DGS02].

tungseigenschaft beschreiben, sofern diese bekannt sind. Gerade bei größeren Schaltungen lassen sich die Eigenschaften jedoch nicht hinreichend genau in all ihren Abhängigkeiten analytisch beschreiben. In diesem Fall kommen Regressionsmodelle oder tabellenbasierte Modelle zum Einsatz, welche das Verhalten der Schaltungseigenschaften auf Grundlage von simulierten oder gemessenen Daten bzw. Stützpunkten modellieren. Dabei handelt es sich um eine Black-Box-Modellierung, da lediglich das äußere Verhalten des Systems Berücksichtigung findet. In dieser Arbeit erfolgt die Erstellung der Performancemodelle mithilfe der Response Surface Modellierung, welche in Abschnitt 3.1.2 erläutert wird.

Die so erstellten Performancemodelle können zum einen separat beispielsweise in MATLAB verwendet werden. Zum anderen werden sie in das Verilog-A Verhaltensmodell der entsprechenden Schaltungskomponente integriert, um so die Parameterabhängigkeiten im Verhaltensmodell berücksichtigen zu können.

Im Codebeispiel 3.2 ist anhand des zuvor gezeigten Beispiels des idealen Verstärkers zu sehen, wie das Verhaltensmodell um ein Performancemodell für den Verstärkungsfaktor $gain$ in Abhängigkeit von der Temperatur erweitert wird. Das Performancemodell liegt dabei als Verilog-A Funktion vor (vgl. 3.3), welche die Modellparameter als Variablen (im Beispiel die Temperatur) enthält. Im Beispiel wird das Temperaturverhalten durch eine quadratische Funktion modelliert. Für die Berechnung erfolgt eine Normierung der Eingangsparameter und anschließend die Berechnung des RSMs.

3.1.2. Response Surface Modellierung

Unter dem Begriff Response Surface Modellierung bzw. Response Surface Methodology sind verschiedene Methoden zur Generierung von Regressionsmodellen auf Basis von Mess- oder Simulationsdaten, den sogenannten Response Surface Modellen (Response Surface Modell (RSM)),

Listing 3.2: Einbindung eines Performancemodells für den Verstärkungsfaktor in Abhängigkeit von der Temperatur in ein Verilog-A-Verhaltensmodell eines einfachen Verstärkers.

```

module amp(in , out , Vdd);
input in , Vdd;
output out;
electrical in , out;

//declare Performance as variable
real gain;

//Include RSM as Verilog-A function
'include " ./gain_RSM_T.va "

analog begin
    //calculate RSM/performancemodel in initial simulation step
    @(initial_step) begin
        gain = gain_RSM($temperature);
    end

    V(out) <+ gain*V(in);

end
endmodule

```

zusammengefasst [BD87]. Dies umfasst sowohl verschiedene Regressionsalgorithmen als auch Methoden zur statistischen Versuchsplanung und der Auswahl der zur Modellierung erforderlichen Stützpunkte. Ursprünglich für die Auswertung und Analyse chemischer Prozesse entwickelt, finden sie Anwendung in vielen Bereichen, die eine Modellierung des Eingangs-Ausgangsverhaltens erfordern. Bei einem Response Surface Modell handelt es sich somit um ein multivariates Approximationsmodell, welches das Verhalten eines als Black-Box betrachteten Systems kontinuierlich abbildet. Zusätzlich bieten die erstellten Modelle die Möglichkeit zur Anwendung diverser Optimierungsverfahren, um die für eine gewünschte Systemantwort optimalen Parameterkonstellationen zu ermitteln, was durch die Erstellung des funktionalen Zusammenhangs zwischen Ein- und Ausgangsgrößen ermöglicht wird.

RSMs werden vielfach für die Modellierung von Schaltungen eingesetzt [HS96], insbesondere auch zur Erfassung des Degradierungsverhaltens. Der hier verwendete Modellierungsansatz basiert im wesentlichen auf den in [Hei15] entwickelten Verfahren. Als Modellfunktionen werden polynomiale Funktionen verschiedener Ordnungen oder Funktionen zur Modellierung stark nichtlinearen Verhaltens wie Radiale Basisfunktionen verwendet. Diese werden im Folgenden vorgestellt.

Listing 3.3: Performancemodell für die Verstärkung. Gezeigt ist hier ein quadratisches Modell in Abhängigkeit von der Temperatur (T).

```

analog function real gain_RSM_T;
input T;
real T, T_norm;

begin
    T_norm = (T - 5.500000000000e+01)/4.500000000000e+01;
    gain_RSM_T = 1.861125000000e+01 + 8.100000000000e-02 * (T_norm)
                -1.125000000000e-02 * pow(T_norm, 2);
end
endfunction

```

Allgemein wird bei der Response Surface Methodology die Ausgangsgröße η eines Systems als Funktion von k Eingangsvariablen ξ beschrieben [BD87].

$$\eta = g(\xi_1, \xi_2, \dots, \xi_k) = g(\boldsymbol{\xi}) \quad (3.6)$$

Aufgrund von Messungenauigkeiten und Abweichungen bei der Wiederholung von Experimenten, für welche die Modellierung ursprünglich entwickelt wurde, kommt es zu Abweichungen bei der beobachteten Systemantwort y . Der Erwartungswert dieser Beobachtung entspricht dem eigentlichen Systemverhalten $E(y) = \eta$. Die Differenz wird als Fehler ϵ angegeben.

$$y = g(\boldsymbol{\xi}) + \epsilon \quad (3.7)$$

Ziel ist es, eine geeignete Modellfunktion $f(\boldsymbol{\xi})$ für den Zusammenhang $g(\boldsymbol{\xi})$ zu finden, welche das Verhalten mit einem möglichst geringen Modellierungsfehler approximiert. Daraus ergibt sich

$$y = f(\boldsymbol{\xi}) + \epsilon_{\text{Model}} \quad (3.8)$$

wobei ϵ_{Model} hier den Fehler des Modells beschreibt.

Im Bezug auf die Erstellung von Performancemodellen aus Gleichung 3.4 mittels RSMs ergibt sich die Modellgleichung

$$\mathcal{P}_k = f_{\text{RSM}}(\mathbf{p}_k) + \epsilon_{\text{RSM}}. \quad (3.9)$$

Dabei ist f_{RSM} die berechnete RSM Funktion, \mathbf{p}_k bezeichnet die Modellparametern und ϵ_{RSM} den Modellfehler.

Zur Erstellung des RSMs erfolgt die Simulation einer begrenzten Anzahl n an Stützstellen \hat{p} , welche in den Stützpunkten resultieren. Aufgrund der sich teilweise stark unterscheidenden Dimensionen der Modellparameter erfolgt eine Normierung der Stützstellen auf den Bereich $-1 \leq \tilde{p}_k \leq 1$ mittels:

$$\tilde{p}_{ki} = \frac{\hat{p}_{ki} - (\max(\hat{p}_{ki}) + \min(\hat{p}_{ki}))/2}{(\max(\hat{p}_{ki}) - \min(\hat{p}_{ki}))/2}. \quad (3.10)$$

Die Genauigkeit der Modellfunktion wird von einer Vielzahl an Faktoren beeinflusst. Zum einen ist sie stark abhängig von der Form der zu modellierenden Zielfunktion als auch von der Anzahl und Lage der Stützstellen, welche je nach Verfahren zur Auswahl der Stützstellen variiert. Verschiedene Verfahren zur Stützpunktauswahl werden im Abschnitt 3.1.3 behandelt. Darüber hinaus ist wie bereits erwähnt die Identifikation der wichtigen Modellparameter für die Modellierung wichtig. Zu diesem Zweck kann eine Sensitivitätsanalyse durchgeführt werden, wodurch diejenigen Parameter gefunden werden, die einen signifikanten Einfluss auf das Schaltungsverhalten bzw. die Performance haben. Der gesamte hier beschriebene Modellierungsvorgang wurde in der MATLAB-Anwendung ReSeMBLeD automatisiert, welche in Abschnitt 3.5 vorgestellt wird.

3.1.2.1. Polynomiale Modelle

In vielen Fällen reicht eine Polynomfunktion niedrigen Grades aus, um das Verhalten in einem begrenzten Definitionsbereich hinreichend genau zu modellieren.

Eine multiple lineare Regression mit einem Polynom ersten Grades ergibt ein lineares Modell der Form

$$f(\mathbf{x})_{\text{lin}} = \beta_0 + \sum_{k=1}^m \beta_k x_k + \epsilon. \quad (3.11)$$

Für ein quadratisches Modell (polynomiale Regression vom Grad 2) ergibt sich entsprechend

$$f(\mathbf{x})_{\text{quad}} = \beta_0 + \sum_{k=1}^m \beta_k x_k + \sum_{k=1}^m \beta_{kk} x_k^2 + \sum_{\substack{k=1 \\ j=k+1}}^m \beta_{kj} x_k x_j + \epsilon \quad (3.12)$$

wobei β die Regressionskoeffizienten und \mathbf{x} die unabhängigen Variablen (Parameter) beschreibt. Die Regressionskoeffizienten werden über die Methode der kleinsten Quadrate (*Least-Squares*) bestimmt:

$$\beta = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{F}. \quad (3.13)$$

Dabei ist \mathbf{F} die Matrix der Stützpunkte, welche sich aus den Simulationsergebnissen der n Stützpunkte ergibt $\mathbf{F} = [F(\tilde{p}_1), F(\tilde{p}_2), \dots, F(\tilde{p}_n)]^T$. Die Matrix der Stützstellen ist durch \mathbf{X} gegeben.

3.1.2.2. Radiale Basisfunktionen

Radiale Basisfunktionen (RBF) sind gut geeignet, um nichtlineares Verhalten zu modellieren und werden daher häufig für RSMs verwendet [MGTM07, HS96]. Bei einer RBF handelt es sich um eine reelle Funktion ϕ , welche radialsymmetrisch ist, deren Wert also vom Abstand zum Ursprung abhängt

$$\phi(\mathbf{x}) = \phi(|\mathbf{x}|). \quad (3.14)$$

Tabelle 3.1.: Beispiele verschiedener radialer Basisfunktionen [MGTM07] welche je nach Art der zu approximierenden Funktion ausgewählt werden können.

Name	Funktion
Gauß	$\phi(r, c) = e^{-(cr^2)}$
Linear	$\phi(r, c) = (r + c)$
Cubic	$\phi(r, c) = (r + c)^3$
Thin Plate Spline	$\phi(r, c) = r^2 \ln(cr)$
Multiquadric	$\phi(r, c) = \sqrt{r^2 + c^2}$
Inverse Multiquadric	$\phi(r, c) = \frac{1}{\sqrt{r^2 + c^2}}$

Als Norm $|\cdot|$ wird dabei meist die euklidische Norm verwendet. Die Approximation einer Funktion $f(x)$ erfolgt durch die Linearkombination mehrerer durch die Koeffizienten β_i gewichteten RBFs

$$f(x) = \sum_{i=1}^n \beta_i \phi(\|\mathbf{x} - \mathbf{x}_i\|, c). \quad (3.15)$$

Dabei bezeichnet \mathbf{x}_i eine Stützstelle, welche auch Zentrum der Basisfunktion genannt wird. Der Formparameter c beeinflusst die Krümmung der Funktion. Zur Vereinfachung wird zudem die Schreibweise $r = \|\mathbf{x} - \mathbf{x}_i\|$ genutzt.

Die Koeffizienten werden so berechnet, dass die Modellfunktion in den Zentren mit den Stützpunkten \mathbf{F} übereinstimmt

$$f(\tilde{\mathbf{p}}_i) = F(\tilde{\mathbf{p}}_i), \quad i = 1, 2, \dots, n \quad , \quad (3.16)$$

womit sich für die Berechnung ergibt:

$$\mathbf{A}\boldsymbol{\beta} = \mathbf{F} \quad . \quad (3.17)$$

Dabei enthält die Matrix $\mathbf{F} = [F(\tilde{\mathbf{p}}_1), \dots, F(\tilde{\mathbf{p}}_n)]^T$ die Stützpunkte und \mathbf{A} die gewählte RBF:

$$\mathbf{A} = \begin{bmatrix} \phi(\|\tilde{\mathbf{p}}_1 - \tilde{\mathbf{p}}_1\|) & \cdots & \phi(\|\tilde{\mathbf{p}}_1 - \tilde{\mathbf{p}}_n\|) \\ \vdots & \ddots & \vdots \\ \phi(\|\tilde{\mathbf{p}}_n - \tilde{\mathbf{p}}_1\|) & \cdots & \phi(\|\tilde{\mathbf{p}}_n - \tilde{\mathbf{p}}_n\|) \end{bmatrix} . \quad (3.18)$$

Unter Verwendung der Methode der Kleinsten-Quadrate können die Koeffizienten damit folgendermaßen bestimmt werden:

$$\boldsymbol{\beta} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{F} \quad . \quad (3.19)$$

In Abbildung 3.3 sind die verschiedenen RBFs aus Tabelle 3.1 über dem Abstand r für verschiedene Formparameter c dargestellt. Dabei wird insbesondere der große Einfluss des Formparameters deutlich, der für die einzelnen Funktionen stark variiert. Insbesondere die Cubic-Kernfunktion zeigt eine starke Veränderung.

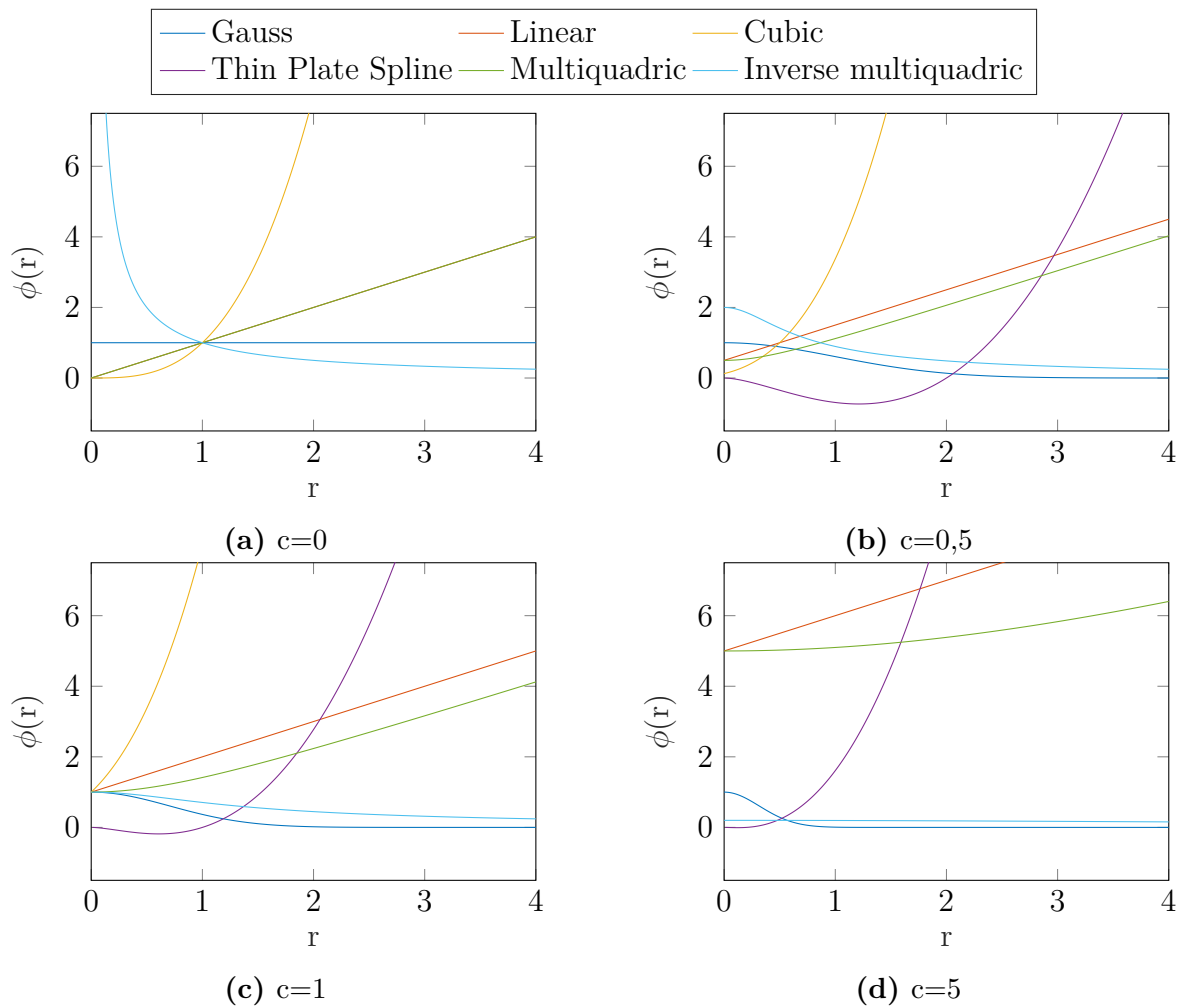


Abbildung 3.3.: Verhalten der einzelnen RBF für verschiedene Werte des Formparameters c .

3.1.2.3. Matérn-Funktionen

Eine weitere Unterart der RBFs stellen die nach dem schwedischen Statistiker Bertil Matérn benannten sog. Matérn-Kovarianz-Funktionen dar [MM05, Ste99, Mat86]. Der Matérn-Kernel ist gegeben durch

$$\phi(r) = \frac{2^{1-\nu}}{\Gamma(\nu)} \left(\frac{\sqrt{2\nu}r}{l} \right)^\nu K_\nu \left(\frac{\sqrt{2\nu}r}{l} \right). \quad (3.20)$$

Dabei ist $\Gamma(\nu)$ die eulersche Gammafunktion und K_ν die modifizierte Besselfunktion zweiter Gattung und ν -ter Ordnung. Die Konstante l ist ein Bereichs- bzw. Abstandsfaktor, während ν den Grad der Glättung angibt. Beide Parameter sind größer als Null. Für $\nu \rightarrow \infty$ ergibt sich die quadrierte exponentielle Kovarianz-Funktion bzw. Gauß-Funktion $e^{-r^2/2l^2}$ als Lösung der Gleichung [WR06]. Sofern $\nu = p + 1/2$ entspricht, wobei p eine positive ganze Zahl ist, lässt

Tabelle 3.2.: Matérn-Funktionen für gängige Werte von p .

Name	Funktion
Matérn ⁰	$\phi(r, c) = e^{-(cr)}$
Matérn ²	$\phi(r, c) = (1 + rc) \cdot e^{-(cr)}$
Matérn ⁴	$\phi(r, c) = (3 + 3cr + (cr)^2) \cdot e^{-(cr)}$

sich die Funktion zu einem Produkt aus einer Exponentialfunktion und einem Polynom des Grads p vereinfachen:

$$\phi_{\nu=p+\frac{1}{2}}(r) = \exp\left(-\frac{\sqrt{2\nu}r}{l}\right) \frac{\Gamma(p+1)}{\Gamma(2p+1)} \sum_{i=0}^p \frac{(p+i)!}{i!(p-i)!} \left(\frac{\sqrt{8\nu}r}{l}\right)^{p-i} \quad (3.21)$$

Für $p = 0, 1, 2$ ergeben sich die meistgenutzten Funktionen:

$$\phi_{\nu=\frac{1}{2}}(r) = \exp\left(-\frac{r}{l}\right) \quad (3.22)$$

$$\phi_{\nu=\frac{3}{2}}(r) = \left(1 + \frac{\sqrt{3}r}{l}\right) \cdot \exp\left(-\frac{\sqrt{3}r}{l}\right) \quad (3.23)$$

$$\phi_{\nu=\frac{5}{2}}(r) = \left(1 + \frac{\sqrt{5}r}{l} + \frac{5r^2}{3l^2}\right) \cdot \exp\left(-\frac{\sqrt{5}r}{l}\right) \quad (3.24)$$

Für die jeweiligen Werte von ν kann der Ausdruck $\sqrt{2\nu}/l$ zu einer Konstante c zusammengefasst werden. Damit ergeben sich die in Tabelle 3.2 dargestellten Funktionen. In der Literatur finden sich unterschiedliche Notationen, wobei entweder ν oder p für die Benennung der Funktionen verwendet wird, die hier verwendete orientiert sich an [Mon11]. Bei dieser Schreibweise wird für die Matérn⁴-Funktion außerdem ein zusätzlicher Faktor in der Konstante c berücksichtigt: $c = 1/3\sqrt{2\nu}/l$.

Die Matérn-Funktion zeichnet sich durch eine hohe Flexibilität aus und kann örtliche Variationen gut modellieren [MM05]. Daher stellt dieser Kernel eine gute Ergänzung zu den „traditionellen“ RBF-Kernen dar und ermöglicht die Modellierung lokal stark variierenden Verhaltens.

3.1.3. Statistische Versuchsplanung

Die statistische Versuchsplanung oder Design of Experiments (DoE) umfasst Methoden zur Erstellung von Versuchsplänen, meist unter der Prämisse mit der geringstmöglichen Anzahl an Experimenten/Stützstellen möglichst viel Erkenntnis über den Zusammenhang zwischen Eingangsparametern und Ergebnissen zu erreichen. Dabei existiert eine Vielzahl an sog. Versuchsplänen, welche eine Liste der durchzuführenden Experimente bzw. der Parameterkombinationen jeder Stützstelle enthalten [MMAC16].

Den einfachsten darunter stellt der vollfaktorielle Versuchsplan dar. Beim vollfaktoriellen Versuchsplan auf 2 Stufen werden pro Parameter (Faktor) jeweils zwei Stufen betrachtet (bspw. -1 und +1), wodurch sich $n = 2^m$ Kombinationen bei m Faktoren ergeben. Werden pro

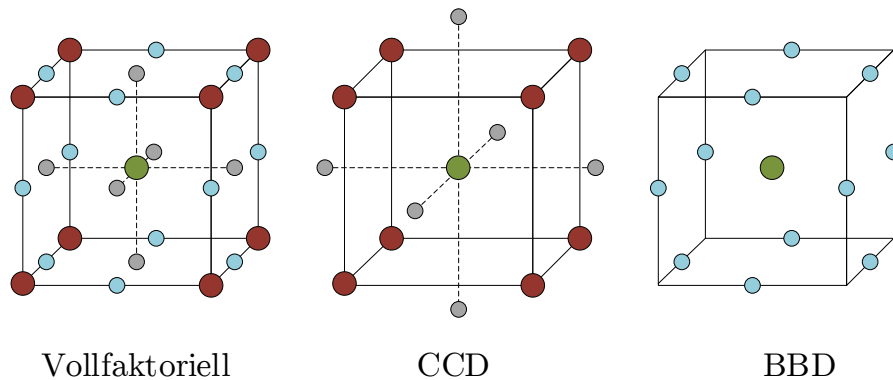


Abbildung 3.4.: Darstellung verschiedener Samplingverfahren: vollfaktorielles Design mit 3 Stufen, CCD und BBD.

Parameter mehr als zwei Stufen, hier s Stufen, berücksichtigt, ergeben sich s^m Kombinationen. Der gesamte Parameterraum wird damit gleichmäßig durch ein mehrdimensionales reguläres Gitter abgedeckt, was i.d.R. zu einer guten Modellgenauigkeit führt. Bei einer größeren Anzahl an Modellparametern muss jedoch eine Abwägung zwischen Modellgenauigkeit und Simulationsaufwand bzw. Stützstellenanzahl getroffen werden.

Zum einen kann neben einem vollfaktoriellen ein teilfaktorieller Versuchsplan verwendet werden. Dabei werden lediglich einige der möglichen Parameterkombinationen im Versuchsplan genutzt. Auch existieren spezielle für die Response Surface Methodology entwickelte Versuchspläne wie das Box-Behnken Design (BBD) [BB60] oder das Central Composite Design (CCD) [MMAC16], welches speziell für quadratische Modelle geeignet ist. Die Verteilung der Stützpunkte für diese Verfahren ist in Abbildung 3.4 gezeigt. Für stark nichtlineares Verhalten sind diese Versuchspläne auf Grund der schlechten Abdeckung jedoch nicht geeignet.

Darüber hinaus existieren Verfahren, welche eine gewählte Anzahl an Stützpunkten statistisch im Parameterraum verteilen. Dazu zählen zum einen das *Latin Hypercube Sampling* (LHS) oder Monte-Carlo-Verfahren. Beim LHS wird der Parameterbereich in gleichgroße Intervalle aufgeteilt, entsprechend der gewählten Anzahl an Stützstellen n , und anschließend eine Zufallsstichprobe pro Intervall gewählt [MBC00]. Dadurch wird eine bessere Abdeckung des Parameterraums erreicht als mit normalen Monte-Carlo-Verfahren.

Bei bereits vorhandener Vorkenntnis über den zu erwartenden Verlauf der zu modellierenden Eigenschaften über ein oder mehrere Parameter kann dieses Wissen in die Erstellung des Versuchsplans einbezogen werden. So ist bspw. bei der Betrachtung von Alterung von einem exponentiellen Verlauf auszugehen, begründet in den verwendeten Alterungsmodellen. In diesem Fall ist es sinnvoll, die Stützstellen des Parameters t_{age} logarithmisch über den Definitionsbereich zu wählen.

Zur Verbesserung der Modellgenauigkeit unter Verwendung möglichst weniger Stützstellen können darüber hinaus adaptive Verfahren angewandt werden. Bei diesen wird zunächst auf Grundlage eines „grobmaschigen“ Versuchsplans ein Modell erstellt und anschließend der Modellfehler anhand zusätzlicher Testpunkte ermittelt. In den Bereichen mit dem größten Mo-

dellfehler werden zusätzliche Stützpunkte generiert und das Modell somit sukzessive verbessert, bis die gewünschte Modellgenauigkeit erreicht wird.

3.1.4. Modellgenauigkeit

Bei der Modellgenauigkeit erfolgt eine Unterscheidung zwischen der Genauigkeit des (RSM-) Performancemodells und der des Verhaltensmodells. Durch die Integration des Performancemodells in ein entsprechendes Verhaltensmodell können neben dem Modellfehler des RSMs weitere Ungenauigkeiten durch Idealisierungen und Modellierungen des Verhaltensmodells auftreten. Der Modellfehler des RSM-basierten Performancemodells wird im Folgenden als ϵ_{RSM} bezeichnet und der Fehler des initialen Verhaltensmodells als ϵ_{VM} bezeichnet. Der Modellfehler des finalen Verhaltensmodell mit dem inkludierten RSM-Performancemodell wird durch $\epsilon_{\text{RSM-VM}}$ angegeben. Grundlegend kann ein Modell nur innerhalb des bei der Erstellung berücksichtigten Definitionsbereichs eingesetzt werden. Dies trifft insbesondere auch auf die hier verwendeten Regressionsmodelle zu, welche nur im Bereich der erhobenen Messdaten gültig sind.

Performancemodell

Die Ermittlung von ϵ_{RSM} kann, je nach gewähltem Regressionsmodell, entweder in den für die die Modellierung verwendeten Stützpunkten geschehen oder durch zusätzliche Testpunkte. Bei der Verwendung von RBFs ist die Bestimmung des Modellfehlers durch zusätzliche Testpunkte zwingend erforderlich, da die RBF mit den Stützpunkten exakt übereinstimmt. Für eine aussagekräftige Bestimmung des Modellfehlers ist es von Vorteil, wenn die gewählten Testpunkte den Definitionsbereich statistisch gut abdecken, wozu wiederum die bereits beschriebenen Verfahren der statistischen Versuchsplanung wie LHS verwendet werden. Die Verwendung zusätzlicher Testpunkte eröffnet zudem wie zuvor erwähnt die Möglichkeit, die Modellgenauigkeit adaptiv zu verbessern durch das Hinzufügen neuer Stützpunkte in Bereichen, in denen der Modellfehler am größten ist.

Für die Bestimmung des Modellfehlers ϵ_{RSM} können verschiedene Fehlermaße verwendet werden [DMGLGR16]. Mit am gängigsten ist die Verwendung eines gemittelten relativen Fehlers (engl. *Mean Absolute Percentage Error* (MAPE), Mittlerer absoluter prozentualer Fehler), welcher definiert ist durch

$$\bar{\epsilon}_{\text{RSMMAPE}} = \frac{1}{N_T} \sum_{i=1}^{N_T} \left| \frac{y(x_{\text{test},i}) - f_{\text{RSM}}(x_{\text{test},i})}{y(x_{\text{test},i})} \right| . \quad (3.25)$$

Neben dem gemittelten Fehler kann auch die Bestimmung des maximalen absoluten Fehlers (*Maximum absolute Error* (maxAE)) von Interesse sein:

$$\epsilon_{\text{RSMmaxAE}} = \max |y(x_{\text{test},1\dots i}) - f_{\text{RSM}}(x_{\text{test},1\dots i})| , \quad (3.26)$$

sowie der mittlere absolute Fehler (*Mean absolute error* (MAE))

$$\bar{\epsilon}_{\text{RSMMAE}} = \frac{1}{N_T} \sum_{i=1}^{N_T} |y(x_{\text{test},i}) - f_{\text{RSM}}(x_{\text{test},i})| \quad . \quad (3.27)$$

Die Modellgenauigkeit des Performancemodells ist grundlegend ausschlaggebend für die Genauigkeit des gesamten RSM-Verhaltensmodells.

Verhaltensmodell

Zur Bestimmung der Genauigkeit des Verhaltensmodells, sowohl des statischen (ϵ_{VM}) als auch des RSM-Verhaltensmodells (ϵ_{RSM-VM}), können verschiedene Maße verglichen werden. Die Ausgangssignale des Verhaltensmodells sollten möglichst genau mit denen des Systems auf Transistorebene übereinstimmen. Dabei ist auch zu berücksichtigen, für welche Simulationsarten das Verhaltensmodell entwickelt und geeignet ist. Als Fehlermaße können hier der vertikale und horizontale Abstand zwischen dem Referenzsignal und der Modellkurve herangezogen werden. Darüber hinaus können die aus den Ausgangssignalen bestimmten Performances bzw. Eigenschaften zur Bestimmung der Modellgenauigkeit ϵ_{VM} verwendet werden, wobei wiederum Referenz- und Modellperformance miteinander verglichen werden. In diesem Fall können die bereits für die Performancemodelle verwendeten Fehlermaße benutzt werden.

Stochastische Verhaltensmodelle

Bei den stochastischen Verhaltensmodellen aus Abschnitt 3.4 werden zusätzliche Maße zur Bestimmung der Modellgenauigkeit benötigt. Der Kolmogorov-Smirnov-Test (KS-Test) mit zwei Stichproben kann eingesetzt werden, um zu überprüfen, ob die Variablen zweier Zufallsstichproben der gleichen Verteilung bzw. Grundgesamtheit angehören [MJ51]. Der Test bewertet Unterschiede der Verteilungsform, u.a. bzgl. der zentralen Tendenz (Mittelwert, Median etc.), der Streuung und Schiefe [HS16]. Dabei wird die absolute Differenz D zwischen den relativen Summenfunktionen bzw. den empirischen Verteilungsfunktionen F_X und F_Y betrachtet, wobei X und Y die entsprechenden Zufallsvariablen darstellen:

$$\hat{D} = \max \left| \hat{F}_{X,n}(x) - \hat{F}_{Y,m}(x) \right| \quad (3.28)$$

Die Nullhypothese H_0 , welche besagt, dass die Zufallsvariablen X und Y die gleiche Verteilung besitzen, sowie die Alternativhypothese ergeben sich zu

$$H_0 : F_X(x) = F_Y(x) \quad H_1 : F_X(x) \neq F_Y(x). \quad (3.29)$$

Wird der kritische Wert D_α bei einem Signifikanzniveau α von \hat{D} erreicht oder überschritten, so wird die Nullhypothese abgelehnt. Dies bedeutet, dass zwischen den untersuchten Verteilungsfunktionen ein statistisch signifikanter Unterschied besteht. Der Kolmogorov-Smirnov-Test mit zwei Stichproben und einem Vertrauensniveau von 1 % wird hier für die Überprüfung der stochastischen Verhaltensmodelle verwendet.

3.2. Schaltungsmodellierung: Stand der Technik

Die Anwendung von Modellierungsmethoden zur Abstraktion des Verhaltens einzelner Schaltungskomponenten oder dedizierter Bauteile ist schon lange Teil der Forschung. Insbesondere mit der fortschreitenden Miniaturisierung in modernen Herstellungstechnologien wächst neben der Komplexität der Schaltungen selbst die Anzahl der Einflussfaktoren auf das Verhalten dieser Schaltungen. In diesem Abschnitt werden einige in der Literatur vorgestellte Methoden zusammengefasst, die ähnliche Ziele wie die in dieser Arbeit entwickelten Modellierungsverfahren haben oder zum Vergleich dienen können. Dazu zählen die Beschleunigung der Simulation sowie die Möglichkeit der Betrachtung der Schaltungseigenschaften und deren Einflüssen auf höheren Abstraktionsebenen. Generell werden Modellierungsmethoden sowohl für digitale als auch für analoge Schaltungen entwickelt und verwendet. Im Folgenden liegt der Fokus auf der Modellierung von Analog- bzw. Mixed-Signal-Schaltungen.

Für die Erstellung von Verhaltensmodellen können verschiedene Methoden verwendet werden. In [SHB08] wird eine automatisierte Verhaltensmodellierung mithilfe symbolischer Analyse und symbolischer Modellreduktion präsentiert.

Die Verwendung von Regressionsfunktionen zur Erstellung von Performancemodellen, wie sie auch in dieser Arbeit zur Anwendung kommen, wird in einigen Veröffentlichungen gezeigt. In [DGS02, DGS03] wird die auch hier verwendete Unterscheidung zwischen Verhaltens- und Performancemodell erläutert. Für die Regression werden dort Posynomialfunktionen verwendet und es findet eine Automatisierung des gesamten Modellierungsprozesses inklusive der Versuchsplanung und Simulation statt. Die Verwendung von Performancemodellen zur Beschleunigung von Simulationen und zur Untersuchung der Machbarkeits-Region (Feasibility region) wurde bereits in [HS96] beschrieben. Dabei werden radiale Basisfunktionen für die Regression genutzt. Der Begriff RSM umfasst, wie zuvor beschrieben, verschiedene Methoden zur Erstellung von Regressionsmodellen, welche das Ein-Ausgangsverhalten eines beliebigen Systems beschreiben. Daher können viele der veröffentlichten Herangehensweisen, in denen Performancemodelle, die einen funktionellen Zusammenhang zwischen Ein- und Ausgangsgrößen einer Schaltung beschreiben, erstellt werden, unter diesem Begriff zusammengefasst werden.

Ein ebenfalls häufig verwendetes Verfahren zur Erstellung von Performancemodellen sind Methoden unter Verwendung von Support Vector Machines (SVMs) [Sat16, KG04, BAS11]. Diese werden zur Bestimmung der Regressionsfunktionen genutzt, wobei, wie bei den RSMs, verschiedene Kernel-Funktionen wie bspw. Polynom-Funktionen oder radiale Basisfunktionen zum Einsatz kommen können.

In der jüngeren Vergangenheit werden zunehmend Methoden aus dem Bereich des Maschinellen Lernens, bspw. neuronale Netze, für die Verhaltensmodellierung betrachtet. Teilweise werden bereits die zuvor erwähnten Verfahren basierend auf SVMs dazugezählt. Darüber hinaus wird in [GLG21] ein Verhaltensmodell einer Ladungspumpe mit ML-Verfahren erstellt. Ein *feed-forward neural network* wird zur Bestimmung einzelner funktionaler Zusammenhänge innerhalb des Modells genutzt. In [SCT⁺21] wird die Optimierung eines Verilog-A Verhaltensmodells mithilfe eines ML-Algorithmus vorgenommen, was eine deutliche Beschleunigung des Optimierungsprozesses bedeutet. Die Simulation eines durch ML-Verfahren erstellten Modells erfordert dessen Implementierung beispielsweise in Verilog-A oder die Co-Simulation des Schaltungssimulators

mit bspw. MATLAB. In [TS21] wird daher eine direkte Kopplung eines Schaltungssimulators mit der ML-Engine TensorFlow beschrieben.

Die Verwendung dieser Modellierungsmethoden zur Erfassung des Alterungsverhaltens von Schaltungen ist mit verschiedenen Schwerpunkten in der Literatur behandelt. Dabei steht vor allem die Beschleunigung der komplexen und zeitaufwendigen Alterungssimulationen, als auch die Ermöglichung der Betrachtung von Alterung auf Systemebene im Fokus. Als Grundlage der in dieser Arbeit entwickelten Modellierungsmethoden kann zudem [Hei15] angeführt werden. Dort wurde eine Methode zur Erstellung RSM-basierter Verilog-A Verhaltensmodelle zur Berücksichtigung alterungsbedingter Degradierungseinflüsse vorgestellt.

Die Berücksichtigung der durch Prozessvariation hervorgerufenen stochastischen Verteilung der Schaltungseigenschaften in Verhaltensmodellen erfordert weitere Modellierungsmethoden. Ein weiterer dabei häufig betrachteter Aspekt ist die Verwendung möglichst weniger Stützpunkte für die Modellierung. Der Aufwand für stochastische Modelle ist hier um ein Vielfaches größer als für die Simulation und Erfassung des nominalen Verhaltens. In [GYH11, LSJ⁺15] werden Methoden zur Erstellung stochastischer Verhaltensmodelle vorgestellt, welche auch nicht Gauss-verteilte Variation modellieren können.

Die Kombination stochastischer Verhaltensmodelle mit alterungsbedingter Degradierung stellt eine weitere Herausforderung dar, da hier die Veränderung der stochastischen Verteilung der Schaltungseigenschaften über die Zeit modelliert werden muss. Dies wird unter anderem in [CWLH15] behandelt, wobei ein Latin-Hypercube-Sampling Verfahren zur Reduktion der benötigten Simulationen für das alterungsabhängige stochastische Verhaltensmodell genutzt wird. [MDJG12] nutzt ein Verfahren zur symbolischen Regression sowie einen *active learning sample selection* Algorithmus zur Verringerung des Simulationsaufwands.

3.3. RSM-basierte Verhaltensmodelle

Die Grundlage der in dieser Arbeit entwickelten PVTA-Verhaltensmodelle stellen die RSM-Verhaltensmodelle dar. Diese basieren auf der Integration eines RSM-Performancemodells, welche charakteristische Schaltungseigenschaften in Abhängigkeit von den Umgebungsparametern beschreibt, in ein entsprechendes Verhaltensmodell der Schaltungskomponente. Die Grundlage für diese Herangehensweise bildet die Arbeit [Hei15].

Der Ablauf der Erstellung RSM-basierter Verhaltensmodelle ist in Abbildung 3.5 dargestellt. Dieser läuft in vier Phasen ab, welche nachfolgend beschrieben werden. Dabei ist zunächst einmal unerheblich, ob Alterung berücksichtigt wird. Dies ist nur für die Simulation der zur Modellierung benötigten Stützpunkte entscheidend und nicht für den Modellierungsablauf an sich, da das Alter lediglich als zusätzlicher Modellparameter betrachtet wird. Für die Erstellung eines reinen Performancemodells ohne die Integration in ein entsprechendes (Verilog-A) Verhaltensmodell endet der Ablauf mit dem Export des RSMs.

Testbench Für die zu modellierende Komponente ist zunächst die Erstellung einer Testbench erforderlich, welche die Simulation der für die Modellierung relevanten Performances \mathcal{P} auf Transistorebene ermöglicht. Dies wird im Folgenden auch als Referenzdesign bezeichnet. Die Erstellung der RSM-Performancemodelle und des (Verilog-A)- Verhaltensmodells

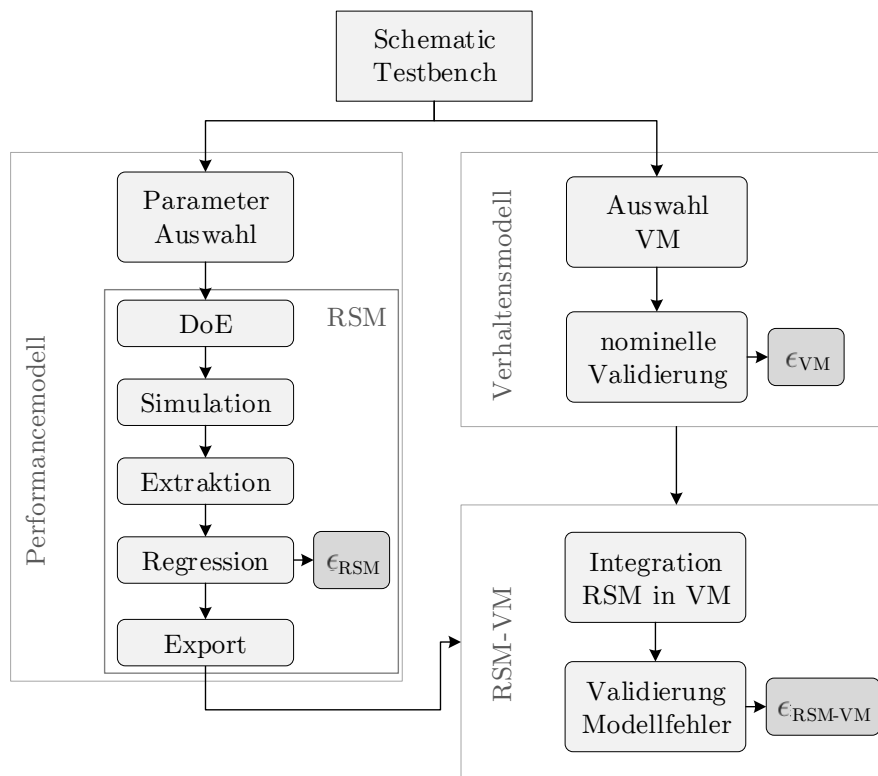


Abbildung 3.5.: Ablauf der Erstellung RSM-basierter Verhaltensmodelle.

erfolgt anschließend getrennt. Die Testbench muss zudem die Variation aller potentiellen Modellparameter ermöglichen.

Verhaltensmodell Entsprechend der zu modellierenden Schaltung wird ein (Verilog-A) Verhaltensmodell erstellt, welches das Systemverhalten abbildet. Dabei kann entweder auf bereits bestehende Verhaltensmodelle zurückgegriffen und diese entsprechend erweitert werden oder ein neues Verhaltensmodell erstellt werden. Das Verhaltensmodell ist durch Verhaltensmodellparameter (VM-Parameter) parametrisiert, die den zu modellierenden Performances entsprechen (bspw. Verstärkungsfaktor und Grenzfrequenz). Um zu überprüfen, ob das gewählte Verhaltensmodell das System hinreichend genau repräsentiert, wird eine primäre Modellvalidierung durchgeführt. Zur Kalibrierung der VM-Parameter werden Performancewerte aus einer nominalen Simulation des Referenzdesigns verwendet. Somit wird der Modellfehler des Verhaltensmodells bestimmt: ϵ_{VM} .

RSM-Erstellung Die Erstellung des RSM-Performancemodells ist in mehrere Schritte unterteilt. Zunächst findet eine Auswahl der relevanten Modellparameter aus den vorhandenen Design- und Umgebungsparametern statt. Das Auswahlkriterium ist dabei der signifikante Einfluss auf die berücksichtigten Performances, wozu eine Sensitivitätsanalyse eingesetzt werden kann. Anschließend erfolgt die eigentliche Erstellung des RSMs mit der Auswahl der zu simulierenden Stützpunkte anhand eines Versuchsplans (DoE). Die Schaltungssimulation wird dann mit dem jeweils geeigneten Simulator (spectre, eldo, Alterungssimulator) ausgeführt und die Schaltungsperformances extrahiert. Auf Basis dieser Simulationsdaten

erfolgt dann die Regression mit den Methoden der RSM. Die Bestimmung des Modellfehlers und eine eventuelle Verbesserung des Modells durch die adaptive Simulation weiterer Stützpunkte wie zuvor beschrieben, ist möglich. Das Performancemodell wird anschließend in dem benötigten Format (Verilog-A-, MATLAB-Funktion) exportiert.

RSM-Verhaltensmodell Um abschließend ein RSM-basiertes Verhaltensmodell zu erhalten, wird das erstellte RSM-Performancemodell in das Verhaltensmodell integriert (siehe 3.2 für die Integration der Verilog-A Funktion). Anschließend kann durch Simulation des Modells und Vergleich mit Simulationsergebnissen des Referenzdesigns der Modellfehler ϵ_{RSM-VM} bestimmt werden.

Für die Simulation des so erstellten Verhaltensmodells ist die Übergabe der Modellparameter an das Modell notwendig. Je nachdem, ob es sich dabei um dem Simulator bekannte Umgebungsvariablen (bspw. Temperatur) oder Eingangssignale der Komponente handelt, müssen diese zusätzlich im Verhaltensmodell aufbereitet werden, um von der Modellfunktion verarbeitet zu werden.

3.4. Stochastische Verhaltensmodelle

Wie bereits beschrieben, ist die Verwendung von RSM-basierten Performance- bzw. Verhaltensmodellen zur Modellierung von integrierten Schaltungen durchaus verbreitet. Die in dieser Arbeit entstandene Weiterentwicklung besteht in der Verwendung dieser RSMs zur Erstellung von stochastischen Verhaltensmodellen, welche die aufgrund von Prozessschwankungen hervorgerufene Variation der Performances modellieren können. Diese neuartige Anwendung wird im Folgenden beschrieben.

Bei der zuvor beschriebenen Modellierungsmethode zur Erstellung RSM-basierter Performancemodelle ist es möglich, die Auswirkungen einzelner Parameter auf das Verhalten der Schaltung zu modellieren. Eine Möglichkeit zur Erstellung stochastischer Verhaltensmodelle ist die Berücksichtigung der einzelnen Prozessparameter als Modellparameter [MR05]. Dadurch kann die Auswirkung jedes einzelnen Prozessparameters auf das Ausgangsverhalten untersucht werden, was bspw. für Optimierungen des Herstellungsprozesses genutzt werden kann. Diese Herangehensweise führt jedoch zu einer sehr großen Anzahl an Modellparametern und damit zu einer hohen Komplexität des Modells und damit einhergehender geringerer Modellgenauigkeit. Darüber hinaus ist die genaue Abhängigkeit von einzelnen Prozessparametern insbesondere auf höheren Abstraktionsebenen nicht unbedingt von Interesse. Die Gesamtverteilung und deren Verhalten bei unterschiedlichen Betriebsbedingungen und Parametern ist allerdings für eine Systemvalidierung und Zuverlässigkeitsanalyse wichtig. Das Ziel dieser Modellierung ist die Erstellung eines stochastischen Verhaltensmodells, welches die PVTA Variationen einer Schaltung oder eines Systems abbilden kann. Dabei wird die Veränderung der durch Prozessvariation hervorgerufenen Verteilung bei unterschiedlichen Betriebsbedingungen modelliert.

Es erfolgt eine Unterscheidung zwischen zwei grundsätzlichen Modellierungsansätzen, je nachdem ob eine parametrische Verteilung wie die Normal- oder Lognormalverteilung vorliegt oder die resultierende Verteilung nicht durch diese beiden Verteilungen abgebildet werden kann.




Abbildung 3.6.: Veränderung der Wahrscheinlichkeitsverteilung der Referenzspannung eines Beta-Multipliers über der Temperatur.

Bei parametrischen Verteilungen, wie den hier betrachteten Normal- und Lognormalverteilungen, werden die zuvor erläuterten RSM-basierten Performancemodelle genutzt, um die Veränderung der Verteilungsfunktion in Abhängigkeit von weiteren Umgebung- und Designparametern abzubilden. Für normalverteilte Performances kann zudem die Berücksichtigung einer Korrelation zwischen den Performances der einzelnen Subsysteme erfolgen. Im Falle einer Verteilung, die nicht durch eine Normal- oder Lognormalverteilung modelliert werden kann, erfolgt die Bestimmung der Verteilungsdichtefunktion mittels Kerndichteschätzung (*Kernel Density Estimation* (KDE)) oder durch ein Gaussian Mixture Model (GMM) und eine anschließende Modellierung per LUT oder RSM.

Zur Veranschaulichung der Herangehensweise ist hier beispielhaft die Verteilung der Ausgangsspannung einer Referenzspannungsquelle gezeigt. Eine genauere Betrachtung dieser Referenzspannungsquelle (Beta-Multiplier) erfolgt im folgenden Kapitel, der Aufbau ist zudem im Anhang A zu finden. In Abbildung 3.6 ist die Veränderung der Wahrscheinlichkeitsdichte über der Temperatur dargestellt. Die Verteilung entspricht in diesem Fall einer Normalverteilung, deren Mittelwert μ und Standardabweichung σ entsprechend durch RSMs modelliert werden und in Abbildung 3.7 gezeigt sind.

Die RSMs werden anschließend in das Verhaltensmodell der Spannungsquelle integriert, in 3.4 ist ein entsprechender Pseudocode gezeigt. In dem Verhaltensmodell wird die Ausgangsspannung dann entsprechend der modellierten Verteilung unter Verwendung der durch die RSMs berechneten Parameter erzeugt.

Im Folgenden wird die durch Prozessvariation hervorgerufene stochastische Verteilung einer Schaltungseigenschaft \mathcal{P} als Performance-Verteilung bezeichnet, deren Modellierung als

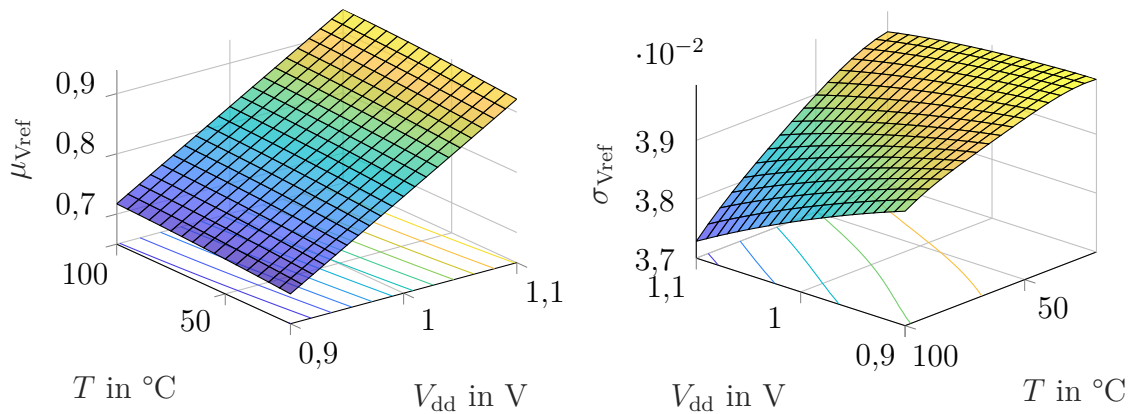


Abbildung 3.7.: RSMs für den Mittelwert μ und die Standardabweichung σ der Referenzspannung V_{ref} des Beta-Multipliers über der Temperatur und der Versorgungsspannung.

Stochastisches Performancemodell (SPM). Dieses kann, wie bereits zuvor für die einfachen Performancemodelle gezeigt, in ein Verhaltensmodell der Schaltungskomponente integriert werden, womit ein Stochastisches Verhaltensmodell (SVM) entsteht.

Der Modellierungsablauf ist in Abbildung 3.8 dargestellt. Hier wird zunächst ein kurzer Überblick über den Modellierungsprozess und die verschiedenen Modellierungsansätze auf Grundlage der vorliegenden Verteilung gegeben. Die einzelnen Modellierungsmethoden werden in den folgenden Abschnitten eingehender erläutert. Wie zuvor wird für jede zu modellierende Schaltung(skomponente) eine Testbench benötigt, welche die Simulation und Ermittlung der für die Modellierung erforderlichen Schaltungseigenschaften \mathcal{P} ermöglicht. Zur Erstellung eines PVTA-Verhaltensmodells müssen hier die Umgebungsparameter, Versorgungsspannung und Temperatur sowie das Alter (VTA) als Modellparameter berücksichtigt werden. Zusätzlich kann die Abhängigkeit von zusätzlichen Eingangssignalen vorgeschalteter Schaltungskomponenten modelliert werden, wenn diese einen signifikanten Einfluss auf das Verhalten haben, so beispielsweise die Bias-Spannung eines Verstärkers.

Wie zuvor bei den RSM-basierten Performancemodellen, wird für die gewählten Modellparameter mithilfe der statistischen Versuchsplanung ein Satz an Stützstellen generiert. Für jeden der n Stützpunkte, welche sich aus den Modellparametern $p_1 \dots p_m$ zusammensetzen, wird eine MC-Simulation durchgeführt. Damit ergibt sich für jeden Stützpunkt eine von der jeweiligen Parameterkombination anhängige Verteilung. Der Simulationsaufwand ist durch die MC-Simulationen bei einer gleichen Anzahl an Modellparametern bedeutend größer als zuvor. Insbesondere die Erstellung eines PVTA-Modells, welches die Abhängigkeit der Verteilung von Alter t_{age} berücksichtigt, erfordert viele Simulationen. In diesem Fall wird t_{age} wie zuvor als Modellparameter betrachtet und die MC-Simulation mit einer Alterungssimulation kombiniert (Monte Carlo + Alterung).

Abhängig von der Verteilungsform wird entschieden, welcher Modellierungsansatz zu wählen ist. Liegt eine Normal- oder Lognormalverteilung vor, so wird die Veränderung von Mittelwert μ und Standardabweichung σ mit RSMs modelliert, womit sich ein sog. μ - σ -RSM SPM ergibt. Liegt eine Normalverteilung vor und es besteht zudem eine Korrelation zu einer anderen Komponente,

Listing 3.4: Pseudocode für das stochastische Verhaltensmodell einer Spannungsreferenz.

```

module Betamultiplier(V_ref);
[... ]
//RSM parameters
parameter real T = 60 from [20:100];
parameter real Vdd = 1 from [0.8:1.1];
//RSM outputs
real mu_Vref;
real sigma_Vref;
//Performance
real Vref;
//distribution parameter
(* cds_inherited_parameter *) parameter real norm_dist = 0;
analog begin
    @(initial_step) begin
        //calculate RSMs
        mu_Vref = RSM_mu(T,Vdd);
        sigma_Vref = RSM_sigma(T,Vdd);
        //Distribution Function
        Vref = norm_dist*sigma_Vref+mu_Vref;
    end
    V(V_ref) <+ Vref;
end
endmodule

```

kann zusätzlich der Korrelationskoeffizient ρ modelliert werden, um diese Korrelation zu berücksichtigen. Das kombinierte Modell wird dann als μ - σ -RSM SPM mit σ -Korrektur bezeichnet.

Bei einer nicht-normalverteilten Verteilung erfolgt zunächst die Bestimmung der Verteilungsdichtefunktion mit KDE oder GMM. Die damit geschätzte Verteilungsdichtefunktion kann entweder als RSM modelliert werden (RSM SPM) oder die Koeffizienten der Approximation werden in einer LUT gespeichert (LUT-basiertes SPM). Da die durch GMM ermittelte Verteilungsdichtefunktion eine geringere Komplexität aufweist als die durch KDE bestimmte, was im späteren Verlauf erläutert wird, eignet sich dieses Verfahren besser zur Anwendung bei den LUT-basierten Modellen.

Die so erstellten stochastischen Performancemodelle können, wie zuvor beschrieben, in Verhaltensmodelle der Schaltungskomponente integriert werden. Für die Berücksichtigung der Stochastik und Verwendung in einer MC-Simulation werden einige zusätzliche Anpassungen des Modells nötig. Diese variieren je nach Anwendung in einer SPICE-Simulation oder MATLAB und werden in den folgenden Abschnitten beschrieben.

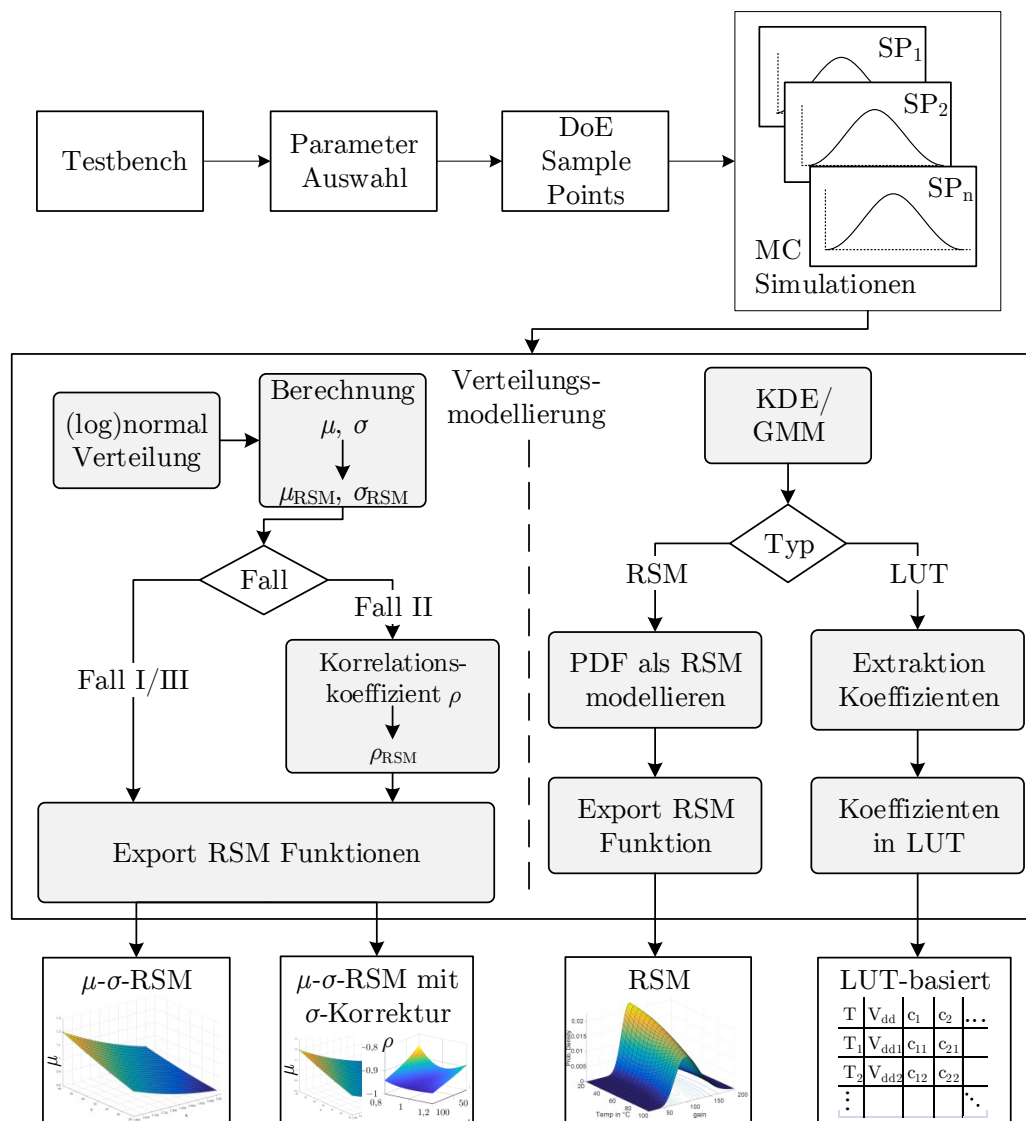


Abbildung 3.8.: Ablauf der Erstellung stochastischer Performancemodelle.

3.4.1. Performancemodellierung parametrischer Verteilungen

In der parametrischen Statistik wird davon ausgegangen, dass die beobachtete Stichprobe Teil einer vorgegebenen Verteilung ist. Im Falle der hier betrachteten Normal- und Lognormalverteilungen sind diese durch den Mittelwert μ sowie die Standardabweichung σ definiert.

Mithilfe der Negativen Log-Likelihood Funktion wird ermittelt, ob die Verteilung mit einer Normal- oder Lognormal-Verteilung modelliert werden kann. Dazu werden die Parameter der Verteilungen auf Grundlage der Ergebnisse der MC-Simulationen berechnet.

Jeder Stützpunkt resultiert damit in einem Wert für den Mittelwert μ_{p_i} und die Standardabweichung σ_{p_i} entsprechend der gewählten Verteilungsfunktion, wie in Tabelle 3.3 gezeigt.

Tabelle 3.3.: Stützpunkte MC-Simulation

	\mathcal{P}_1		\mathcal{P}_2		\dots	\mathcal{P}_m	
SP ₁	μ_{11}	σ_{11}	μ_{21}	σ_{21}		μ_{m1}	σ_{m1}
SP _n	μ_{12}	σ_{12}	μ_{22}	σ_{22}		μ_{m2}	σ_{m2}
\vdots							
SP _n	μ_{1n}	σ_{1n}	μ_{2n}	σ_{2n}		μ_{mn}	σ_{mn}

Für den Mittelwert μ sowie die Standardabweichung σ werden anschließend RSMs berechnet, welche die Abhängigkeit von den Modellparametern modellieren:

$$\mu_{\mathcal{P}_i} = \mu_{RSM} = f_{RSM}(p_1, p_2, \dots, p_m) \quad (3.30)$$

$$\sigma_{\mathcal{P}_i} = \sigma_{RSM} = f_{RSM}(p_1, p_2, \dots, p_m). \quad (3.31)$$

Um bei der Simulation des stochastischen Verhaltensmodell Zufallszahlen zu erzeugen, die der modellierten Verteilung folgen, werden Gauß-verteilte Zufallszahlen generiert und der resultierende Performance-Wert entsprechend

$$\mathcal{P}_{i_{norm}} = \mathcal{N}(0,1) \cdot \sigma_{\mathcal{P}_i} + \mu_{\mathcal{P}_i} \quad (3.32)$$

$$\mathcal{P}_{i_{lognorm}} = \exp(\mathcal{N}(0,1) \cdot \sigma_{\mathcal{P}_i} + \mu_{\mathcal{P}_i}). \quad (3.33)$$

für normal und lognormal Verteilungen berechnet.

Integration in Verhaltensmodell

Werden die RSMs als Verilog-A Modell verwendet, erfolgt die Integration in ein entsprechendes Verhaltensmodell folgenderweise: Die RSMs werden wie zuvor als Verilog-A-Funktion eingebunden und mithilfe der übergebenen Parameter berechnet, wie im Beispielcode 3.5 gezeigt. Daraus ergeben sich der Mittelwert und die Standardabweichung. Darauf folgend wird der Performancwert entsprechend 3.33 bestimmt. Standardnormalverteilte Zufallswerte werden während der MC-Simulation vom Simulator erzeugt und über den Parameter `norm_dist` an das Verhaltensmodell übergeben. Dazu müssen diese als zusätzlicher Parameter deklariert und mit ihrer entsprechenden Statistik, in diesem Fall die Standardgaußverteilung mit Standardabweichung $\sigma = 1$, definiert werden. Die Datei mit der Definition dieser Stochastik-Parameter wird zusätzlich vom Simulator eingelesen (3.6).

Für jede Einzelsimulation innerhalb der MC-Simulation wird somit ein Wert für die Performance erzeugt, der der modellierten Verteilung entspricht.

Listing 3.5: Einbindung der RSMs für Mittelwert und Standardabweichung mit je zwei Parametern in ein stochastisches Verhaltensmodell. Der Parameter `normdist` wird während der MC-Simulation vom Simulator generiert und liefert standardnormalverteilte Zufallszahlen.

```

module BehavioralModel ([...]);
[...]
//RSM parameters
parameter real par1 = 25;
parameter real par2 = 80;
//distribution parameter
(* cds_inherited_parameter *) parameter real norm_dist = 0;
//include RSMs
'include "RSM_mu.va"
'include "RSM_sigma.va"
//define variables
real mu, sigma, Performance;
analog begin
    //calculate RSMs
    mu = RSM_mu(par1, par2);
    sigma = RSM_sigma(par1, par2);
    //Distribution Function
    Performance = norm_dist*sigma+mu;
    [...]
end
endmodule

```

Listing 3.6: Definition standardnormalverteilter Zufallszahlen für die Simulation.

```

parameters norm_dist = 0
statistics {
    mismatch {
        vary norm_dist dist=gauss std=1
    }
}

```

3.4.1.1. Betrachtung von Korrelationen

In einem größeren System, das aus mehreren Teilsystemen besteht, können Korrelationen zwischen den einzelnen Performances oder in Bezug auf PVTA-Einflüsse bestehen. So wird z. B. die Verstärkung eines Verstärkers durch eine Bias-Spannung beeinflusst und korreliert daher mit der Schwankung der Bias-Spannung aufgrund von Prozessvariationen. Ansätze, die nur Prozessvariationen modellieren, können die Korrelation auf Systemebene nicht richtig beschreiben. Im Falle normalverteilter korrelierter Performances im Modell kann eine Korrektur angewendet werden, die die Korrelation berücksichtigt. Dieser Ansatz ist jedoch für die oben genannten KDE/GMM-Modelle nicht anwendbar, da er auf der linearen Kombination zweier normalverteilter Variablen basiert.

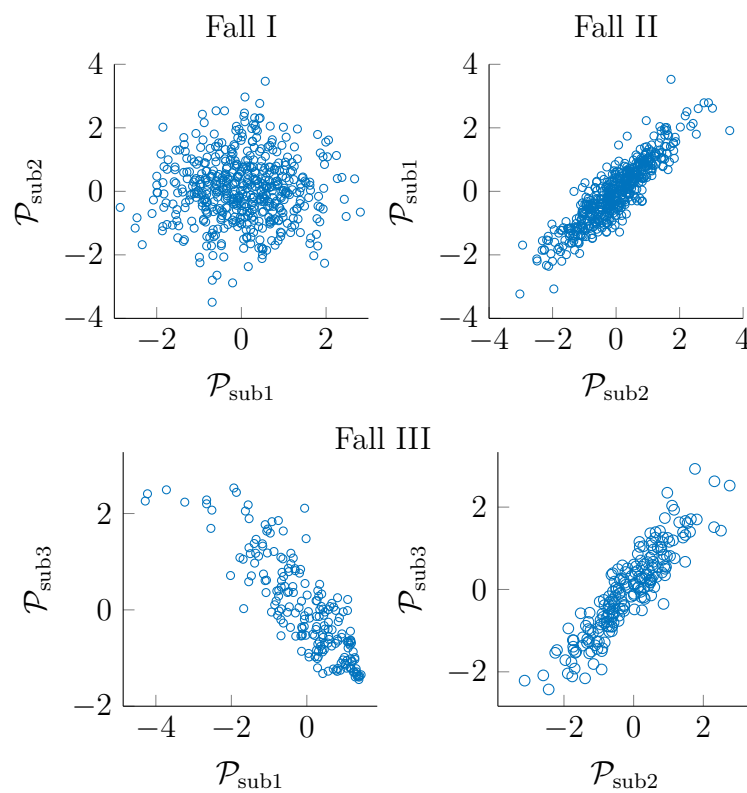


Abbildung 3.9.: Darstellung verschiedener Korrelationen zwischen (Teil-) Schaltungsleistungen $\mathcal{P}_{\text{sub}\square}$ und/oder Parametern entsprechend den beschriebenen Fällen.

Bei diesem Ansatz werden die Systeme entsprechend ihrer spezifischen Art der Korrelation in drei Fälle kategorisiert, die in Abbildung 3.9 dargestellt sind.

Fallunterscheidungen

Fall I Wenn die betrachteten Subsysteme unkorrelierte Performances haben, kann eine hierarchische Modellierung direkt erfolgen: Jedes Subsystem kann einzeln mit einem μ - σ -RSM modelliert werden und die resultierenden Verteilungen können mit Standard-Monte-Carlo-Methoden extrahiert werden.

Fall II Die Performance eines Teilsystems $\mathcal{P}_{\text{sub}2}$ ist mit der Performance eines vorhergehenden Teilsystems $\mathcal{P}_{\text{sub}1}$ korreliert. Liegt nur eine Korrelation vor, so kann diese durch Berechnung des Korrelationskoeffizienten berücksichtigt werden und das Systemmodell seriell aufgebaut werden. Das bedeutet, dass man vom Eingang des Systems ausgeht und mit der Modellierung des ersten Subsystems beginnt. Anschließend wird dieses Subsystemmodell verwendet, um das SPM des folgenden Subsystems zu bestimmen.

Ein einfacher Ansatz, um die Korrelation zwischen zwei Subsystemen einzubeziehen, ist die Neuberechnung der resultierenden Standardabweichung unter Verwendung der Korrelation zwischen den beiden Subsystemen. Wenn zwei Variablen $(X_{\text{sub},1}, X_{\text{sub},2})$ normalverteilt sind, ist das Ergebnis ihrer Linearkombination ebenfalls normalverteilt mit der Standardabweichung σ_{12} , die durch [MS16] gegeben ist:

$$\frac{\sigma_{12}}{\mu_{12}} = \sqrt{\left(\frac{\sigma_{\text{sub},1}}{\mu_{\text{sub},1}}\right)^2 + \left(\frac{\sigma_{\text{sub},2}}{\mu_{\text{sub},2}}\right)^2 \pm 2 \cdot \rho_{12} \cdot \frac{\sigma_{\text{sub},1} \cdot \sigma_{\text{sub},2}}{\mu_{\text{sub},1} \cdot \mu_{\text{sub},2}}} \quad (3.34)$$

Dabei bezieht sich $\square_{\text{sub},\square}$ auf einen Parameter des Subsystems und ρ_{12} ist der Pearson-Korrelationskoeffizient. ρ_{12} wird durch die gemeinsame Simulation der beiden Subsysteme in einer gemeinsamen Testbench ermittelt. Die Standardabweichung ist auf den entsprechenden Mittelwert normiert, um die unterschiedlichen Dimensionen der Performances und Parameter zu berücksichtigen. Im Folgenden wird das resultierende SPM als μ - σ -RSM mit σ -Korrektur bezeichnet. $\mu_{\mathcal{P}_i}$ und $\sigma_{\mathcal{P}_i}$ werden wie zuvor beschrieben für die einzelnen Subsysteme mit RSMs modelliert. Die Berechnung der σ -Korrektur erfolgt anschließend während der Simulation im Verhaltensmodell.

Wie in Gl. 3.34 zu sehen ist, wird für die σ -Korrektur der Korrelationskoeffizient ρ zwischen den beiden beteiligten Teilsystemen benötigt. Je nach System und Performance kann ρ entweder (nahezu) konstant über den modellierten Betriebsbereich sein oder sein Wert kann sich in Abhängigkeit von den anderen Modellparametern \mathbf{p} ändern. In diesem Fall kann die Verschiebung von ρ ebenfalls mit einem RSM (ρ_{RSM}) modelliert werden, um die Modellgenauigkeit weiter zu erhöhen.

Fall III Ist eine Performance mit mehreren Performances anderer Teilsysteme korreliert, ist die σ -Korrektur aus Fall II nicht anwendbar. Es ist in diesem Fall jedoch möglich, ein Systemmodell zu erstellen, das die korrelierten Subsysteme in einem μ - σ -RSM-Modell zusammenfasst.

3.4.2. Performancemodellierung nicht-normaler Verteilungen

Lässt sich die Performance-Verteilung nicht mit einer Normal- oder Lognormalverteilung modellieren, müssen Methoden angewandt werden, die in der Lage sind, die Wahrscheinlichkeitsdichtefunktion (PDF) einer komplex geformten Verteilung zu ermitteln. Im folgenden werden zwei Verfahren vorgestellt.

Das resultierende SPM kann auf zwei Weisen erstellt werden: Zum einen können die aus der Bestimmung der PDF resultierenden Koeffizienten in einem LUT-basierten Modell gespeichert

werden. Eine weitere Möglichkeit ist die kontinuierliche Modellierung der PDF über den Parameterraum mithilfe von RSMs.

Für die Bestimmung von Zufallszahlen entsprechend der ermittelten Verteilung wird hier auf das Slice-Sampling zurückgegriffen, welches im Anschluss beschrieben wird.

Kerndichteschätzung (KDE)

Eine Möglichkeit stellt die Verwendung der Kerndichteschätzung (*kernel density estimation (KDE)*) zur Schätzung der Wahrscheinlichkeitsdichtefunktion dar. Dieses nicht-parametrische statistische Verfahren ermöglicht die stetige Schätzung einer unbekanntes Wahrscheinlichkeitsdichtefunktion anhand einer Stichprobe.

Für eine Stichprobe x_1, \dots, x_n vom Umfang n einer unbekanntes Verteilungsdichte f ergibt sich die Kerndichteschätzung zu

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (3.35)$$

wobei K den Kern bezeichnet und h die Bandbreite darstellt.

Die Wahl der Bandbreite ist für die Genauigkeit und Robustheit der Schätzung von großer Bedeutung. Der in [BGK⁺10] vorgeschlagene Algorithmus wird hier zur Bestimmung einer geeigneten Bandbreite angewendet.

Als Kern kann prinzipiell eine beliebige Dichtefunktion verwendet werden, beispielhaft können hier die Cauchy- oder Epanechnikov-Kerne genannt werden. In dieser Arbeit werden die häufig benutzten Gauß-Kerne verwendet [SN12]

$$K(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}x^2\right). \quad (3.36)$$

Die Kerndichteschätzung ist damit aufgrund der Summierung eine Überlagerung der skalierten Kerne, deren Zentren an jedem Punkt aus der Stichprobe positioniert sind. Die Anzahl an Kernen der Kerndichteschätzung entspricht damit dem Umfang der Stichprobe, im Bezug auf die Performancemodellierung also der Anzahl der MC-Punkte. Dies führt zu einer großen Anzahl an Kernen in der Linearkombination aus Gleichung 3.36 und somit zu einem hohen Rechenaufwand bei der Auswertung der PDF.

Gaussian Mixture Model (GMM)

Eine weitere Möglichkeit zur Ermittlung der PDF ist die Verwendung eines Gaussian Mixture Models (GMM) oder Gaußschem Mischmodell. Dabei handelt es sich um probabilistische Modelle, die in der Statistik und beim maschinellen Lernen für Clustering und Dichteschätzung verwendet werden. Sie gehen davon aus, dass die Daten aus einer Mischung von Gauß-Verteilungen erzeugt werden. Jede Komponente in dem Mischmodell stellt ein Cluster dar, das durch seinen Mittelwert und seine Kovarianzmatrix charakterisiert wird. GMMs ermöglichen damit die Erfassung komplexer Verteilungen durch die Kombination mehrerer Gauß-Komponenten. Im

Gegensatz zur KDE wird dabei eine begrenzte Zahl an Gauß-Kernen (Komponenten) verwendet, wodurch die Komplexität der resultierenden PDF deutlich geringer ist.

GMMs können auch für die Erfassung multivariater Verteilungen verwendet werden, hier wird lediglich der eindimensionale Fall betrachtet. Die Wahrscheinlichkeitsdichte ergibt sich zu

$$\hat{f}_h(x) = \sum_{i=1}^k w_i \mathcal{N}(x_i | \mu_i, \sigma_i^2). \quad (3.37)$$

Dabei gibt k die Anzahl der Komponenten des GMM an, w_i die jeweiligen Gewichtungsfaktoren (auch Mischproportionen) und μ_i und σ_i^2 die Mittelwerte und Varianzen. \mathcal{N} ist gegeben durch

$$\mathcal{N}(x_i | \mu_i, \sigma_i^2) = \frac{1}{\sqrt{2\pi\sigma_i^2}} \exp\left(-\frac{(x_i - \mu_i)^2}{2\sigma_i^2}\right). \quad (3.38)$$

Für die Bestimmung der Modellparameter wird der Expectation-Maximization (EM) Algorithmus verwendet [DLR77, MLR19]. Dabei handelt es sich um ein iteratives Verfahren zur Optimierung und zum Auffinden (lokaler) maximum likelihood Parameter eines statistischen Modells. Ausgehend von initialen Werten für die Mittelwerte, Varianzen und Gewichtungsfaktoren, erfolgt eine Optimierung bis eine Konvergenz erreicht wird.

Die Wahl der Anzahl k der Komponenten kann frei getroffen werden. Für die Gewichte gelten folgende Nebenbedingungen:

$$\sum_{i=1}^k w_i = 1 \quad \text{und} \quad 0 \leq w_i \leq 1. \quad (3.39)$$

Aufgrund der geringeren Anzahl an Komponenten eignet sich das GMM besser zur Verwendung in dem LUT-basierten SPM und wird daher im Folgenden verwendet.

3.4.2.1. LUT-basiertes Modell

Der Ablauf zur Erstellung eines LUT-basierten stochastischen Modells unter Verwendung der GMM ist in Abb.3.10 dargestellt. Monte-Carlo-Simulationen werden für verschiedene Betriebsbedingungen (unterschiedliche Temperatur T , Versorgungsspannung V_{dd} usw.) durchgeführt. Für jede MC-Analyse wird ein GMM berechnet, um die resultierende PDF zu berechnen. Die Koeffizienten des Modells w , μ und σ werden für jede simulierte Parameterkombination in einer LUT gespeichert. Das SPM enthält dann das Gaußmodell, wobei die Koeffizienten aus der LUT gewonnen werden. Bei der Verwendung des Modells wird ein Slice Sampling durchgeführt, um Zufallsstichproben aus einer Verteilung für eine ausgewählte Betriebsbedingung zu ziehen. Zwischen den Einträgen in der LUT kann eine lineare Interpolation zur Ermittlung der nicht simulierten Parameterkombinationen durchgeführt werden.

3.4.2.2. RSM-basiertes Modell

Neben dem LUT-basierten Ansatz kann die nicht-normale Performanceverteilung, deren PDF durch das GMM dargestellt wird, auch kontinuierlich mit einem RSM modelliert werden.




Abbildung 3.10.: Erstellung eines LUT-basierten SPMs mittels GMM.

In diesem Fall wird die resultierende PDF über die jeweilige Performance modelliert. Die Performance selbst wird dazu als ein zusätzlicher Modellparameter für das RSM behandelt. Somit ist die Wahrscheinlichkeitsdichteverteilung gegeben durch:

$$P_{\mathcal{P}_i k} = f_{RSM}(\mathbf{p}_k, \mathcal{P}_k) \quad (3.40)$$

Dies ermöglicht auch die Berechnung der Verteilung bei Werten, die sich von den simulierten Stichprobenpunkten, d. h. den Betriebsbedingungen, unterscheiden, ohne die Notwendigkeit einer Interpolation zwischen den Einträgen in dem zuvor betrachteten LUT-basierten Ansatz. Diese Approximierung ist jedoch mit der Einschränkung verbunden, dass die stochastischen Eigenschaften nicht berücksichtigt werden, da es sich beim RSM um ein Black-Box-Modell handelt. Bei der durch das RSM approximierten PDF wird die Nebenbedingung, dass das Integral gleich 1 sein muss, nicht erfüllt. Diese Approximierung kann somit lediglich für Abschätzungen und zur globalen Analyse der zu erwartenden Verschiebung der Variation über die modellierten Parameter genutzt werden und nicht für eine Zuverlässigkeitsanalyse.

3.4.2.3. Slice Sampling

Um die stochastischen Verhaltensmodelle in einer MC-Simulation verwenden zu können, müssen Zufallszahlen generiert werden, die der modellierten Verteilung entsprechen. Im Falle der zuvor betrachteten parametrischen Verteilungen ist dies verhältnismäßig einfach durch die Verwendung standardnormalverteilter Zufallszahlen möglich. Das Slice Sampling stellt eine Methode dar, um Zufallszahlen einer beliebigen statistischen Verteilung generieren zu können [Nea03]. Es handelt sich dabei um ein Markov-Chain-Monte-Carlo-Verfahren (MCMC), bei dem Zufallszahlen gleichverteilt unterhalb der Kurve der Wahrscheinlichkeitsdichtefunktion f ausgewählt werden. Der Name der Methode ergibt sich aus der Erzeugung gleichmäßiger horizontaler Schnitte, aus denen eine auf oder unter der PDF-Kurve liegende Stichprobe zufällig gezogen wird.

Der Ablauf des Slice Sampling Algorithmus für eine reelwertige Variable läuft folgendermaßen ab [Nea03]:

- ein Startwert x_0 wird gewählt für den gilt $f(x_0) > 0$




Abbildung 3.11.: Auswahl einer neuen Zufallszahl mittels Slice Sampling.

- die Hilfsvariable y wird gleichverteilt aus dem Intervall $[0, f(x_0)]$ ausgewählt, dies definiert einen horizontalen Schnitt (*Slice*)
- um den Startwert herum wird ein Intervall gebildet, welches das gesamte bzw. so viel wie möglich des Slices enthält
- aus dem Intervall wird gleichverteilt ein neuer Wert x_1 gesampelt, welcher unterhalb der Kurve liegt. Damit beginnt der Algorithmus von vorn.

Für die Bildung des Intervalls zur Auswahl des neuen Samples existieren verschiedene Herangehensweisen. Die in MATLAB implementierte und damit hier verwendete Methode ist die sog. *stepping-out*-Methode [Mat12]. Dabei wird zunächst ein Intervall der Breite w beliebig um den Startwert x_0 gelegt, wie in Abbildung 3.11 gezeigt. Dieses Intervall wird so lange in beide Richtungen erweitert, bis die Endpunkte außerhalb des durch die Wahrscheinlichkeitsdichtefunktion f definierten Wertebereichs liegen. Anschließend wird innerhalb des so entstandenen Intervalls ein Wert x gleichverteilt ausgewählt. Liegt x innerhalb des definierten Wertebereichs von f , wird dieser Wert als neues Sample x_1 angenommen. Liegt dieser außerhalb des Wertebereichs, so wird die Intervallgrenze auf x gesetzt und das Intervall entsprechend verkleinert. Anschließend wird in dem verkleinerten Intervall erneut gesampelt, bis ein passender Wert gefunden ist. Dieses Vorgehen wird solange wiederholt bis die gewünschte Anzahl an Zufallszahlen erreicht wurde.

3.5. Automatisierte Modellerstellung

Um die vorgestellte Modellierungsmethode zu automatisieren, wurde das Tool ReSeMBleD (Response Surface Model Behavioral Description) als eine MATLAB-Anwendung (App/Toolbox) mit grafischer Benutzeroberfläche implementiert. Es basiert auf der in [Hei15] präsentierten

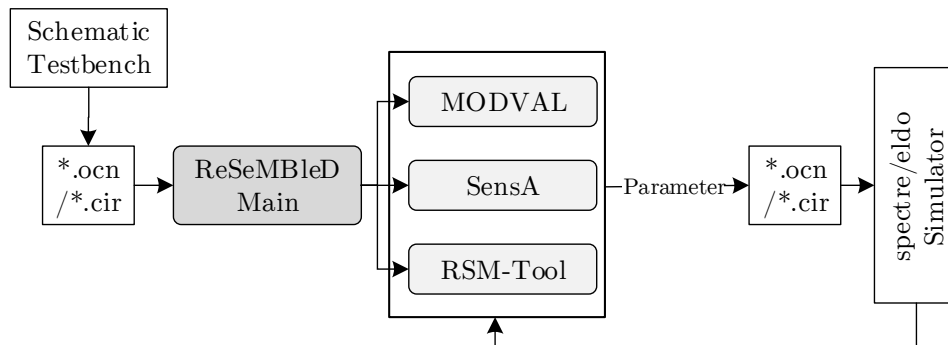


Abbildung 3.12.: Aufbau der MATLAB-Anwendung ReSeMBleD und Kommunikation mit dem Schaltungssimulator.

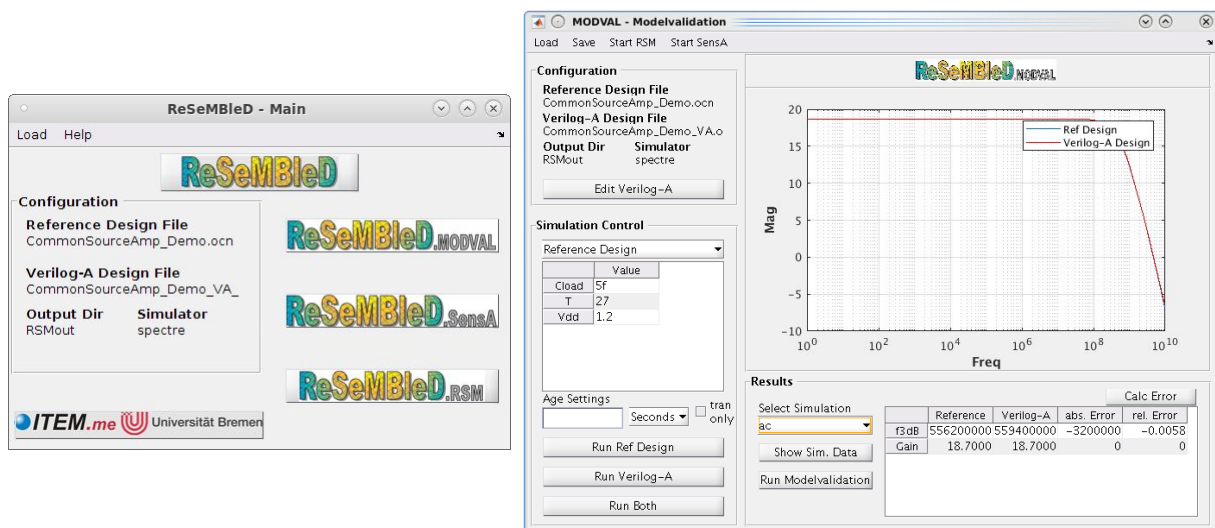


Abbildung 3.13.: Benutzeroberflächen des Hauptmenüs von ReSeMBleD sowie des MODVAL-Tools.

Anwendung, wurde jedoch grundlegend neu implementiert und um zahlreiche Funktionen erweitert, insbesondere zur Erstellung stochastischer Performancemodelle. Aufgrund der gewählten objektorientierten Implementierung können zusätzliche Funktionalitäten und Erweiterungen einfach realisiert werden. Das Tool besteht aus drei Teilanwendungen für die einzelnen Aufgaben der Modellerstellung, wie in Abb. 3.12 dargestellt. Die einzelnen Teilanwendungen können auch separat verwendet werden. Insbesondere das RSM-Tool eignet sich neben der automatisierten Erstellung von Performancemodellen von Schaltungen zur Berechnung von Regressionsmodellen aus verschiedenen Datenquellen, z.B. Messdaten oder Simulationsergebnissen aus anderen, nicht direkt eingebundenen Simulationen. Nachfolgend werden die Funktionalitäten der Anwendungen kurz erläutert.

Die Verwendung des Tools setzt einige Anforderungen an den Aufbau und die Umsetzung der zu modellierenden Schaltung in der Designumgebung. Die Testbench der zu modellierenden Original-Schaltungskomponente auf Transistorebene, im Folgenden Referenzdesign genannt,

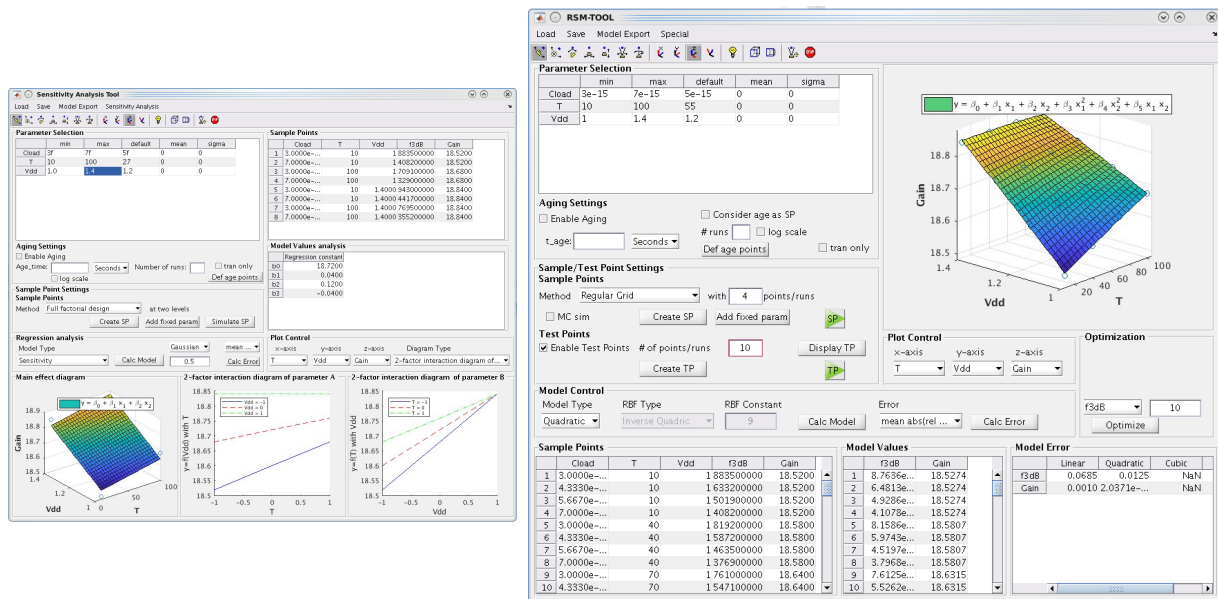


Abbildung 3.14.: Benutzeroberflächen des SensA- und RSM-Tools.

muss die Simulation und die Berechnung der zu modellierenden Performances ermöglichen. Mögliche Modellparameter müssen als Variablen deklariert werden, um die automatisierte Analyse zu ermöglichen. Für die Modellvalidierung ist eine zusätzliche Testbench für das Verilog-A-Verhaltensmodell der Schaltungskomponente erforderlich. Das Verhaltensmodell beschreibt das Gesamtverhalten und die Spannungs-/Stromverhältnisse an den Anschlüssen des Bauteils. Im ersten Validierungsschritt enthält das Verhaltensmodell noch keine RSMs.

Die Initialisierung und Einrichtung des Tools erfolgt über eine Haupt-GUI (Abb. 3.13). Hier werden alle Pfade, die zur Ausführung der Anwendung erforderlich sind, vom Benutzer definiert, sowie evtl. erforderliche Simulations-Skripte. Die Informationen können in einer Konfigurationsdatei gespeichert werden. Die Anwendung ermöglicht automatische Simulationen innerhalb des Cadence Design Environment, entweder für Cadence Virtuoso's Spectre oder Mentor Graphics eldo-Simulator. Um die automatische Simulation über ReSeMBleD zu ermöglichen, muss die Referenzdesign-Testbench alle Parameter sowie die Simulationen und Berechnung der gewünschten Performances beinhalten. Das Simulationsskript kann entweder als Ocean-Skript (Spectre) oder als .cir-Netzliste (eldo) gespeichert werden. Darüber hinaus ermöglicht ReSeMBleD eine automatisierte Simulationsumgebung für den eldo-Alterungssimulator von Mentor-Graphics. Das Einlesen und Einrichten von Simulations-Skripten sowie von Ergebnissen erfolgt über Python-Skripte. Diese steuern die Übergabe der erforderlichen, vom Benutzer definierten Parameter an die Simulationskripte und deren kommandozeilenbasierte automatisierte Ausführung.

Nachfolgend werden die drei Teilanwendungen und ihre Funktionen kurz vorgestellt:

MODVAL - Modell-Validierung Mit Hilfe des Subtools MODVAL kann die Gültigkeit und Genauigkeit der Verilog-A-Verhaltensbeschreibung analysiert und direkt mit der Simulation des Referenzdesigns verglichen werden. Die Validierung erfolgt durch den Vergleich der Ausgangswellenformen (*waveforms*) sowie der daraus berechneten Perfor-

mancewerte (siehe Abbildung 3.13). Die für die Simulation zu verwendenden Parameter werden vom Benutzer festgelegt.

Die Modellvalidierung ist entsprechend Abbildung 3.5 der erste und der letzte Schritt des Prozesses zur Bestimmung der Modellfehler ϵ_{VM} und ϵ_{RSM-VM} . Sie dient dazu, sicherzustellen, dass die Funktionalität durch die Verhaltensbeschreibung korrekt dargestellt wird, sowohl mit als auch ohne Einbeziehung von RSMs. Für die erste bzw. initiale Modellvalidierung werden die nominalen Performancewerte des Referenzdesign verwendet. Falls erforderlich, können Anpassungen am Verhaltensmodell vorgenommen werden. Nach der Einbindung der RSM wird die Modellgenauigkeit ϵ_{RSM-VM} in einer abschließenden Modellvalidierung bewertet. Zur Erfassung des Fehlers über den gesamten modellierten Entwurfsraum können statistisch verteilte Testpunkte verwendet werden.

SensA - Sensitivitätsanalyse Für die hier angewandte Sensitivitätsanalyse kann entweder ein vollfaktorieller oder ein teilfaktorieller Versuchsplan gewählt werden, je nach Anzahl der Parameter. Die Haupteffekte und Interaktionseffekte, die den Koeffizienten einer linearen Regressionsfunktion entsprechen, geben Informationen über den direkten Einfluss eines Parameters auf die Eigenschaften der Schaltung sowie über die Wechselwirkung zwischen einzelnen Parametern. Die GUI des entsprechenden ReSeMBleD-Subtools SensA ist in Abbildung 3.14 abgebildet: Die Ergebnisse können in Haupteffekt- und 2-Faktor-Interaktionsdiagrammen dargestellt werden. Zusätzlich werden die Koeffizienten der linearen Regression angezeigt.

RSM-Tool - RSM Erstellung Die eigentliche Erstellung von RSMs besteht, wie zuvor beschrieben, aus mehreren Schritten: Auswahl der Stützpunkte, Simulation, Extraktion, Regressionsmodellierung, Modellgenauigkeit und Modellexport. Dies ist der Hauptteil des Tools zur Entwicklung der eigentlichen Regressionsfunktionen, dessen Benutzeroberfläche in Abbildung 3.14 dargestellt ist. Zu den Funktionen dieses Subtools gehören:

- Definition der Parametergrenzen der Modellierungsregion
- Generation/Auswahl der Stützstellen anhand von DoE,
- Simulation und Import der Simulationsergebnisse
- Berechnung verschiedener Regressionsfunktionen und direkte graphische Ausgabe des resultierenden RSM
- Bewertung der Modellgenauigkeit mit Testpunkten
- Export des RSM als MATLAB- oder Verilog-A-Funktion (automatische Einbindung in ein Verhaltensmodell ist optional)
- für stochastische Modelle: Monte-Carlo-Simulation, automatische Berechnung der Best-Fit-Verteilung und ihrer Parameter.

Die verschiedenen zuvor beschriebenen statischen Versuchspläne stehen zur Generierung der Stützpunkte zur Auswahl: Reguläres Gitter, Latin Hypercube, Box-Behnken-Design und Central-Composite-Design. Das Stichprobenverfahren (und gegebenenfalls die Anzahl

der Punkte) kann vom Benutzer ausgewählt werden. Darüber hinaus können manuell weitere Stützpunkte hinzugefügt werden, der Versuchsplan wird dann automatisch angepasst. Als Regressionsmodelle stehen die drei in Abschnitt 3.1.2 genannten Arten zur Verfügung: polynomiale Modelle erster bis dritter Ordnung sowie radiale Basisfunktionen (RBFs) und Matérn Funktionen. Der Regressionstyp muss vom Benutzer ausgewählt werden. Für RBFs und Matérn-Funktionen kann ein grundlegender Optimierungsalgorithmus von MATLAB angewendet werden, um den am besten passenden Formparameter c für die ausgewählte Funktion zu finden.

Für die Berechnung des Modellierungsfehlers sind zusätzliche Testpunkte erforderlich. Um eine gute Abdeckung des Modellierungsraums zu gewährleisten, wird Latin Hypercube Sampling verwendet, um eine benutzerdefinierte Anzahl von Testpunkten zu generieren. Sobald alle Simulationen abgeschlossen sind, können verschiedene Fehlermaße verglichen werden, um das beste Modell zu finden. Darüber hinaus können nach einer initialen Simulation zusätzliche Stützpunkte generiert werden, um die Modellgenauigkeit zu verbessern. Das dazu implementierte adaptive Sampling-Verfahren generiert in der Umgebung von Testpunkten weitere Stützpunkte, wenn der Modellfehler dort eine Toleranzgrenze überschreitet. Der Vorteil des adaptiven Samplings ist, dass die Abdeckung durch Stützpunkte lokal in Bereichen großer Modellfehler und nicht global verfeinert wird. Dadurch kann die Anzahl der benötigten Simulationen zum Erreichen einer benötigten Modellgenauigkeit gegenüber nicht adaptiven Verfahren zum Teil deutlich reduziert werden.

Alle simulierten Stütz- und Testpunkte können zur späteren Verwendung gespeichert werden. Zusätzlich können Daten aus anderen Quellen, die in einer .mat-Datei gespeichert sind und die Formatierungsanforderungen erfüllen, in das Tool geladen werden, um RSMs zu erstellen.

Wird während der Initialisierung des Tools ein Verilog-A Verhaltensmodell angegeben, kann eine automatische Einbindung der RSMs in das Verhaltensmodell entsprechende des in 3.2 gezeigten Beispiels erfolgen. Einige abschließende Anpassungen müssen manuell vorgenommen werden, z.B. das Löschen von Parametern, die nun von der RSM berechnet werden.

Speziell für die Erstellung stochastischer Performancemodelle bietet das RSM-Tool weitere Funktionen. Die Verteilungsfunktion kann entweder vom Nutzer gewählt werden oder es wird mithilfe der Negativen Log-Likelihood Funktion die am besten passende Verteilung ausgewählt.

3.6. Zusammenfassung

Dieses Kapitel behandelt die Grundlagen der in dieser Arbeit verwendeten Modellierungsmethoden zur Erstellung von Performancemodellen mittels Response Surface Modellen für die Darstellung der Veränderung charakteristischer Schaltungseigenschaften in Verhaltensmodellen. Dazu wird auf die Regressionsmodellierung mittels RSM an sich, sowie auf die Entwicklung geeigneter Versuchspläne mithilfe von Design of Experiments und die Ermittlung der Modellfehler

eingegangen. Anschließend werden die damit in dieser Arbeit entwickelten Modellierungsansätze für RSM-basierte sowie stochastische Verhaltensmodelle vorgestellt. Zuletzt wird mit der MATLAB-Anwendung ReSeMBleD ein im Zuge dieser Arbeit entwickeltes Tool zur automatisierten Umsetzung der beschriebenen Modellierungsverfahren präsentiert.

PVTA-Modelle integrierter Schaltungskomponenten

In diesem Kapitel werden die Ergebnisse zu den in Kapitel 3 vorgestellten Modellierungsmethoden zur Erstellung von PVTA-Verhaltensmodellen dargestellt. Dabei werden für die verschiedenen in Kapitel 3 betrachteten Fälle Beispielschaltungen in Simulationen untersucht und modelliert. Zunächst erfolgt die Beschreibung der dafür verwendeten Beispielschaltungen, anschließend werden die aus den Simulationen gewonnenen Ergebnisse präsentiert und diskutiert.

4.1. Beispielschaltungen

Zur Evaluation der Modellierungsmethode werden verschiedene Beispielschaltungen genutzt, welche im Folgenden vorgestellt werden.

4.1.1. OTA-Schaltung

Eine Operationsverstärkerschaltung mit Operations-Transkonduktanzverstärker (Operational Transconductance Amplifier (OTA)) sowie den notwendigen zusätzlichen Subsystemen zur Bereitstellung der Bias-Spannungen dient als Beispiel eines hierarchischen Systems mit Korrelation. Für die Simulation werden die in [Hil18, HPPD18] vorgestellten prädiktiven Transistormodelle für einen 65nm-Prozess verwendet, welche die Simulation von Prozessvariation und Alterung ermöglichen. Die Gesamtschaltung, bestehend aus einem Beta-Multiplier als Referenzspannungsquelle, einem Distributionsnetzwerk zur Bereitstellung der verschiedenen benötigten Bias-Spannungen sowie dem OTA selbst, ist in Abbildung 4.1 dargestellt. Die Schaltungen des Beta-Multipliers und des OTA auf Transistorebene sind in Abbildung 4.2 gezeigt. Alle Schaltungen inklusive ihrer Dimensionierung sind zudem im Anhang A gezeigt. Dieses OTA-System kann bspw. innerhalb eines C-V-Wandlers und der Verstärkungsstufe eines Sensorinterface eingesetzt werden. Der OTA hat einen Rail-to-Rail-Eingang, da es bspw. in einem Sensorinterface verwendeten Beschleunigungssensoren zu hohen Ausschlägen im Eingangssignal kommen kann.

Für die hierarchische Modellbetrachtung wird das System in die zwei in Abbildung 4.1 gezeigten Subsysteme geteilt. Die vom Beta-Multiplier erzeugte Referenzspannung V_{ref} stellt damit ein Eingangssignal für das Subsystem, bestehend aus Distributionsnetzwerk und OTA, dar. Im Folgenden wird zunächst die Beta-Multiplier-Schaltung einzeln betrachtet, um das

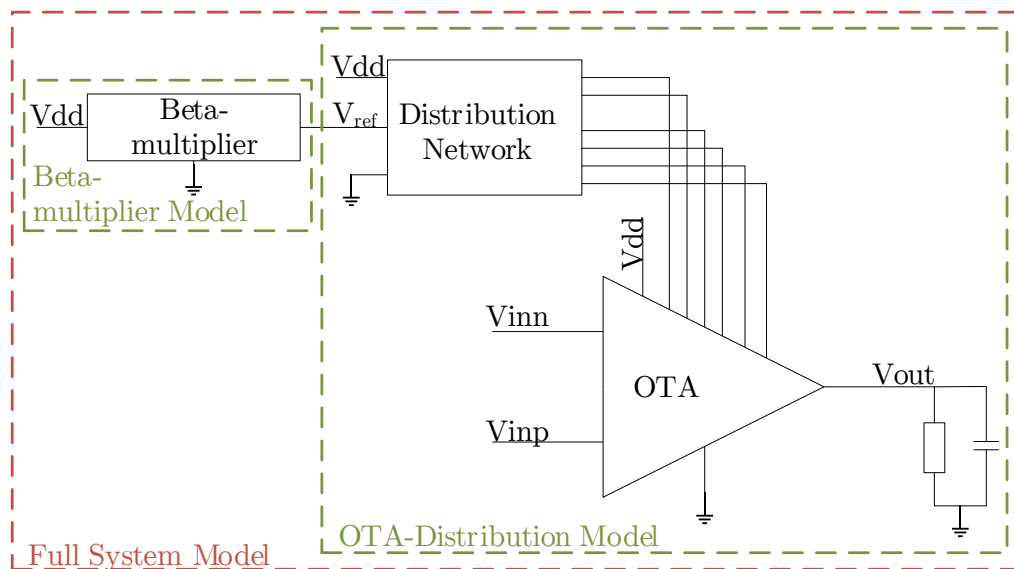


Abbildung 4.1.: Unterteilung der Sub-Systeme für das stochastische Verhaltensmodell des OTA.

Modellierungsverfahren für eine einzelne Schaltung zu präsentieren. Anschließend erfolgt eine hierarchische Modellierung des Gesamtsystems.

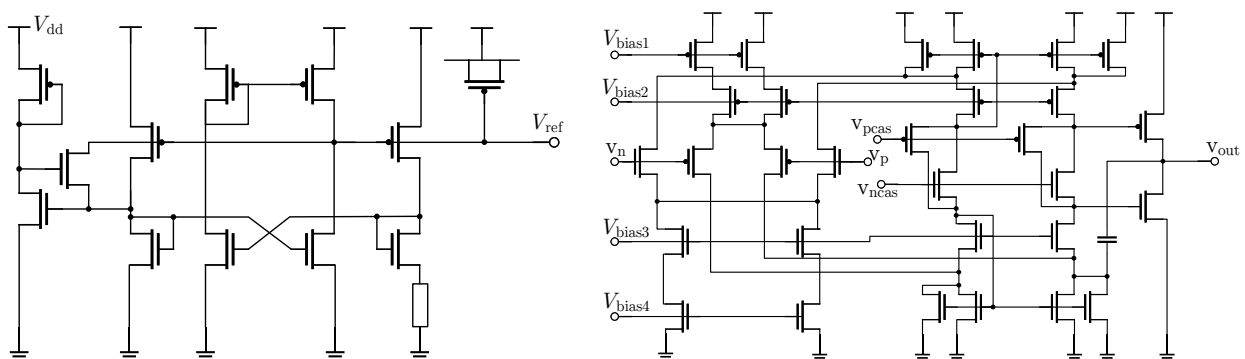


Abbildung 4.2.: Beta-Multiplier und OTA Schaltung auf Transistorebene nach [Bak10].

4.1.2. Komparator

Als Beispiel für ein System bestehend aus Komponenten ohne Korrelation zwischen den betrachteten Performances dient hier ein getakteter Komparator mit RS-Latches an den Ausgängen. Der Aufbau ist in Abbildung 4.3 dargestellt. Die Gesamtleistung wird als zu modellierende Performance betrachtet. Diese ergibt sich aus der Addition der Leistungsaufnahme der beiden einzelnen Leistungsaufnahmen des Komparators und des Latches:

$$P_{System} = P_{Komparator} + P_{Latch}. \quad (4.1)$$

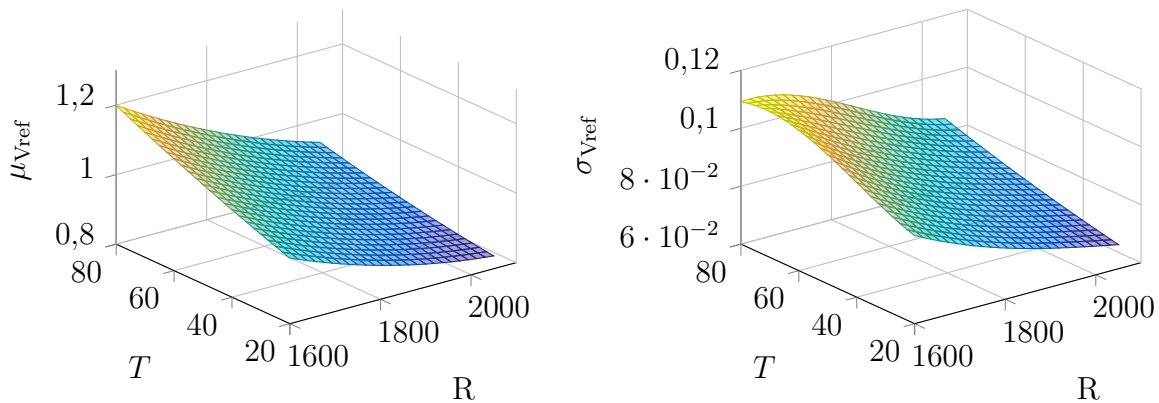


Abbildung 4.5.: RSMs für den Mittelwert μ und die Standardabweichung σ der Referenzspannung V_{ref} des Beta-Multipliers über der Temperatur und dem Widerstand.

Dabei wird die Variation der Referenzspannung V_{ref} des Beta-Multipliers aus der zuvor gezeigten Operationsverstärkerschaltung in Abbildung 4.2 als einzelne Schaltung betrachtet, analysiert und modelliert. Als Parameter werden die Temperatur $T = \{20.. 80\}$ °C und der Widerstand $R = \{1600.. 2050\}$ Ω von ihren Nominalwerten $T = 27$ ° und $R = 1853$ Ω variiert. Für jede der 16 Stützstellen, die mit einem regulären Gitter (vollfaktoriellen Design) mit vier Faktoren pro Parameter konstruiert wurden, werden 200 MC-Simulationen durchgeführt. Die Ergebnisse werden mit einer Normalverteilung gefittet, die nach dem BIC eine gute Repräsentation der Daten darstellt. Die Abbildungen 4.5 zeigen die resultierenden RSMs für den Mittelwert $\mu_{V_{\text{ref}}}$ und die Standardabweichung $\sigma_{V_{\text{ref}}}$ der Referenzspannung. Der Mittelwert wird mit einer quadratischen RSM modelliert, während die Standardabweichung am genauesten durch eine Gaußsche radiale Basisfunktion dargestellt werden kann.

Um die Genauigkeit des stochastischen Modells zu bewerten, werden für die Schaltung auf Transistorebene (Referenzschaltung) und das Verhaltensmodell Testpunkte simuliert, die von den ursprünglichen Abtastpunkten abweichen. Die Ergebnisse sind in Abbildung 4.6 dargestellt und zeigen, dass die Verteilung für verschiedene Parameterkombinationen gut erfasst wird. Die Form der Verteilungen des Verhaltensmodells ähneln einander, da für jeden MC-Lauf derselbe Seed verwendet wurde, was zu derselben Folge von normalverteilten Zahlen führt. Ein Vergleich der Mittelwerte und Standardabweichungen für die Testpunkte ist in Tabelle 4.1 dargestellt. Der relative Fehler liegt für alle bis auf einen Testpunkt deutlich unter 1%. Darüber hinaus sind in Abbildung 4.7 die Histogramme und Probability Plots (P-P-Diagramme) überlagert dargestellt, welche die hohe Genauigkeit der Modellierung noch einmal grafisch verdeutlichen.

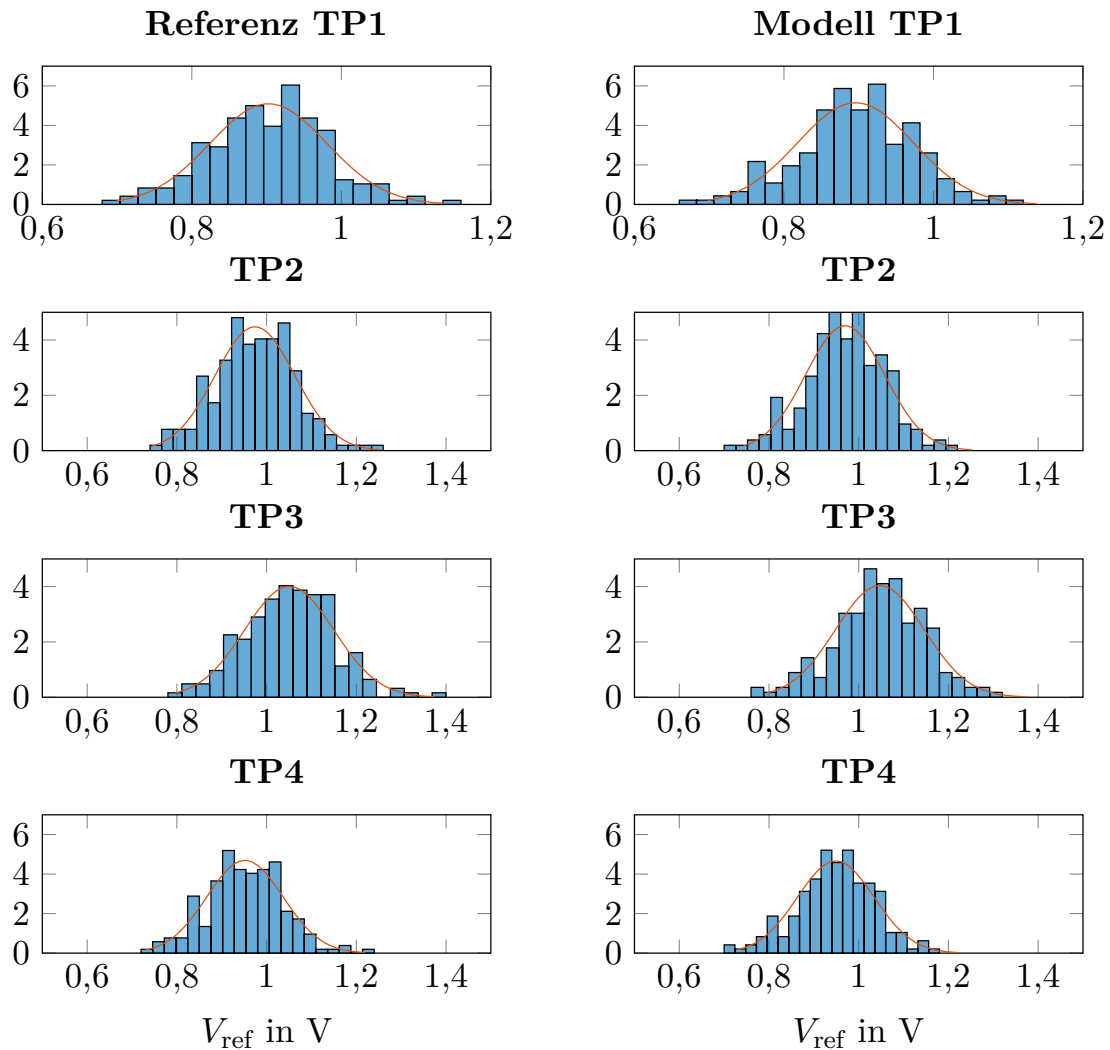


Abbildung 4.6.: Vergleich der Verteilungen für V_{ref} aus 200 MC-Simulationen zwischen der Referenzschaltung und dem stochastischen Verhaltensmodell in vier Testpunkten mit $T = \{30, 70, 50, 25\} \text{ } ^\circ\text{C}$ und $R = \{1853, 1900, 1650, 1700\} \text{ } \Omega$.

Tabelle 4.1.: Vergleich der Kennwerte der Verteilungen der MC Simulation der Referenzschaltung und des Verhaltensmodells des Beta-Multiplier.

Test Punkt	T	R	Referenz		Modell		rel. Fehler	
			μ	σ	μ	σ	$\epsilon_{\text{rel}\mu}$	$\epsilon_{\text{rel}\sigma}$
1	30 °C	1853 Ω	0.9025	0.0783	0.8957	0.0775	0.0075	0.0101
2	70 °C	1900 Ω	0.9741	0.0891	0.9697	0.0883	0.0045	0.0084
3	50 °C	1650 Ω	1.0505	0.0995	1.0471	0.0987	0.0032	0.0081
4	25 °C	170 Ω	0.9517	0.0850	0.9490	0.0856	0.0028	-0.0065

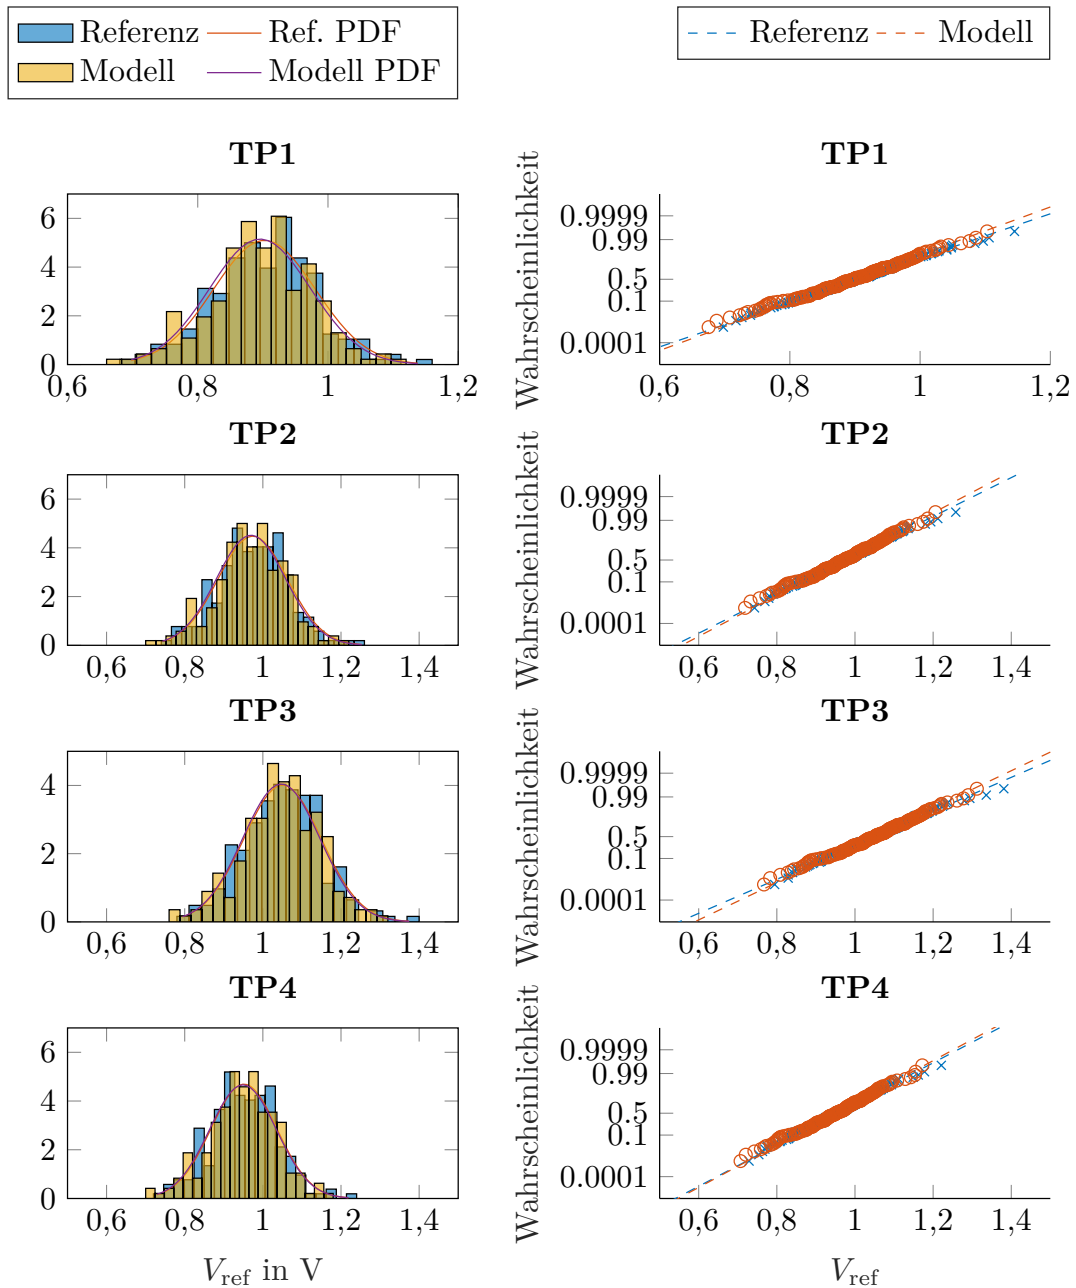


Abbildung 4.7.: Vergleich der Verteilungen für V_{ref} aus 200 MC-Simulationen zwischen der Referenzschaltung und dem stochastischen Verhaltensmodell in den vier Testpunkten als überlagerte Histogramme sowie Probability Plots.

4.2.2. Hierarchische Modellierung

In diesem Abschnitt wird nun die Erstellung stochastischer Verhaltensmodelle für hierarchische Systeme betrachtet, anhand der in Abschnitt 3.4.1 definierten Fälle. Für jedes System werden zwei Modelle erstellt: 1) Einzelmodelle für die Sub-Komponenten sowie 2) ein vollständiges Gesamtsystemmodell zu Vergleichszwecken.

4.2.2.1. Unkorreliertes System

Zunächst erfolgt die Modellierung eines unkorrelierten Systems, wozu als Beispiel die DC-Leistungsaufnahme des zuvor vorgestellten Komparators mit einem RS-Latch an seinen Ausgängen modelliert und ausgewertet wird.

Die Leistungsaufnahme des Komparators wird für einen Temperaturbereich von $T = 20\text{ °C}$ bis $T = 100\text{ °C}$ und einen Eingangs-Gleichtaktbereich von $V_{cm} = 450\text{ mV}$ bis $V_{cm} = 550\text{ mV}$ analysiert. Die Leistungsaufnahme der beiden Subsysteme ist unkorreliert, wie durch den Scatterplot in Abbildung 4.8 deutlich wird, so dass das in Fall I beschriebene Verfahren angewendet werden kann.

Wie aus Abbildung 4.10 ersichtlich wird, kann die Leistungsvariation mit einer Lognormalverteilung beschrieben werden. Zur Modellierung der Verschiebung von μ_{logn} und σ_{logn} werden quadratische RSMs verwendet. Die RSMs für das Gesamtsystemmodell sind in Abbildung 4.9 gezeigt. Dabei zeigt sich eine starke Temperaturabhängigkeit der Leistungsaufnahme, während die Auswirkung der Eingangs-Gleichtaktspannung erwartungsgemäß vernachlässigbar gering ausfällt. Die erstellten RSMs werden in entsprechende Verhaltensmodelle für das Gesamtsystem (Systemmodell) sowie für die Einzelkomponenten Komparator und Latch integriert. Abbildung 4.10 zeigt die Verteilung für das Gesamtsystemmodell sowie die Einzelmodelle im Nominalpunkt. Es ist zu erkennen, dass der Latch den Hauptbeitrag zur Gesamtleistungsaufnahme leistet. Bei der Überlagerung der Verteilungen zeigt sich zudem eine gute Übereinstimmung zwischen dem Systemmodell und dem hierarchischen Modell.

Zur Beurteilung der Modellgenauigkeit werden beide Modelle sowie die Referenzschaltung auf Transistorebene in 10 Testpunkten ausgewertet. Wie in Abbildung 4.11 gezeigt, wird die Verschiebung der Verteilung bei verschiedenen Temperaturen und Gleichtaktspannungen von beiden Modellen insgesamt gut erfasst. Bei einzelnen Testpunkten ist eine stärkere Abweichung von der Referenzschaltung zu erkennen.

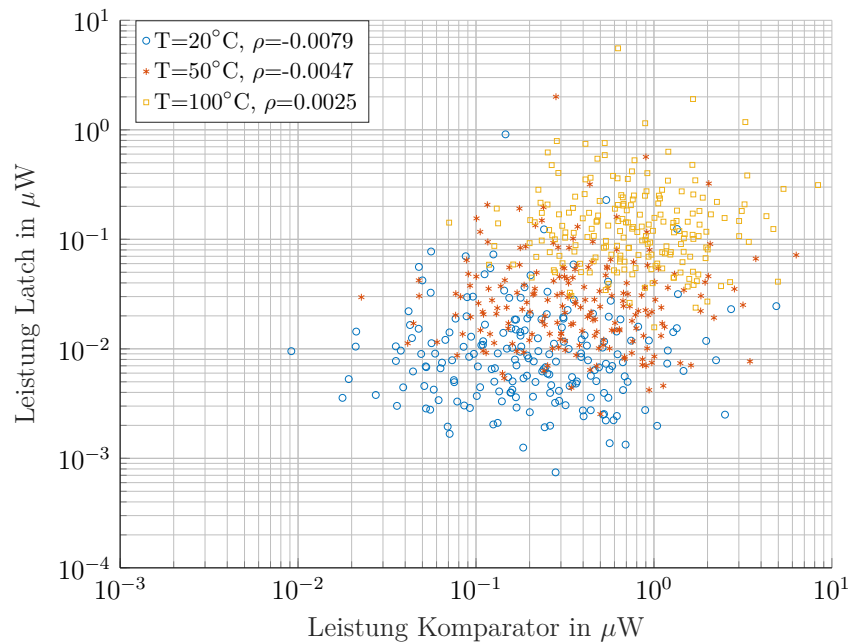


Abbildung 4.8.: Streudiagramm (scatter plot) der Leistungsaufnahme von Komparator und Latch. Die Leistungsaufnahmen können als unkorreliert betrachtet werden.




Abbildung 4.9.: Quadratische RSMs des Gesamtsystemmodells für die Leistungsaufnahme des Komparators inkl. Latches.

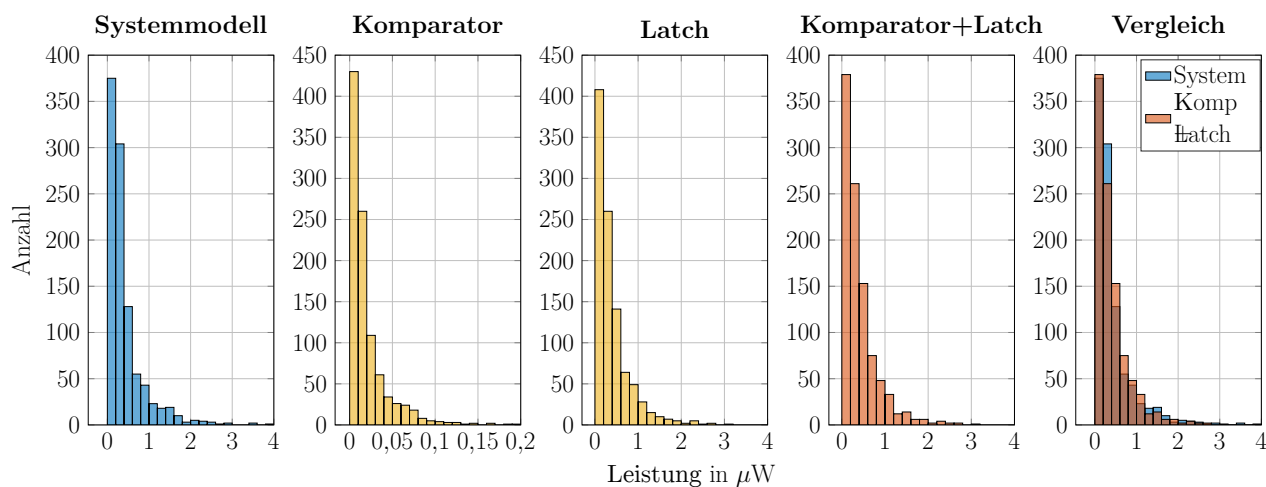


Abbildung 4.10.: Vergleich der Leistungsvariation für das Gesamtsystemmodell und das serielle Modell (Komparator+Latch) im Nominalpunkt $\{T = 27^\circ\text{C}, V_{cm} = 500\text{ mV}\}$.

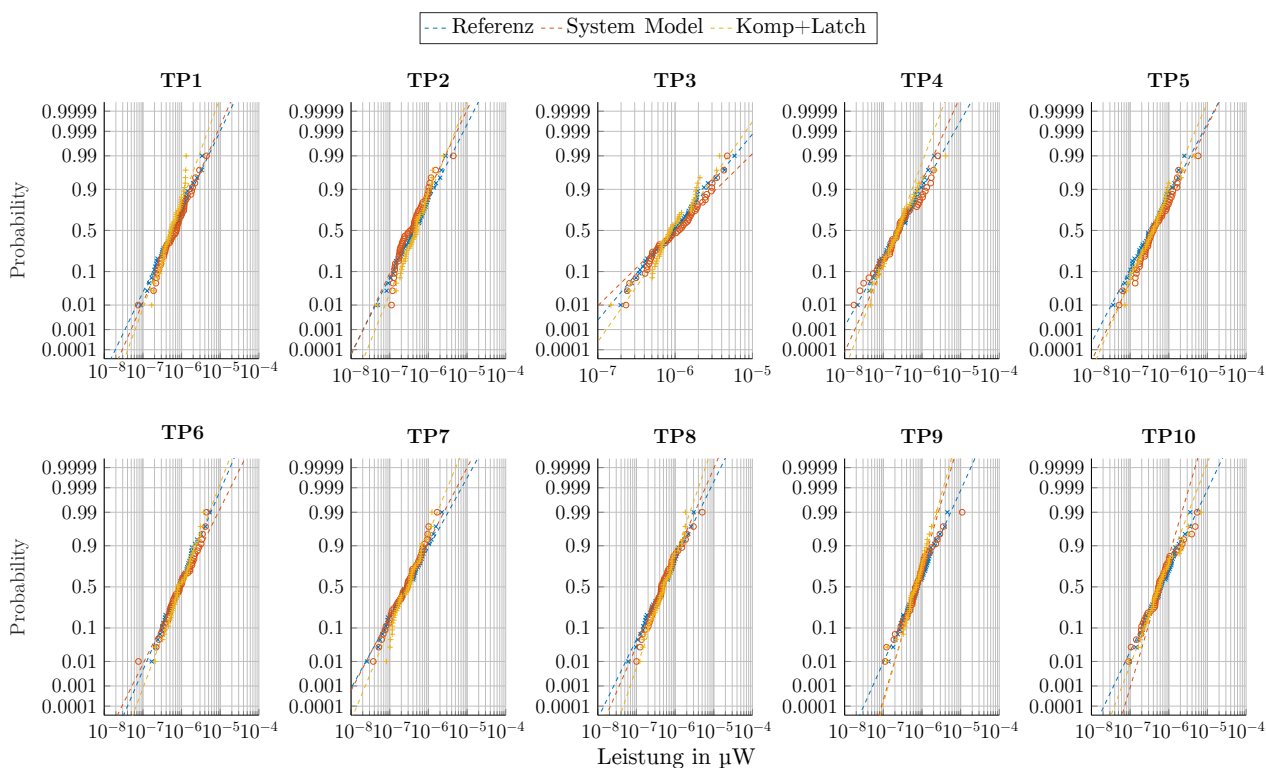


Abbildung 4.11.: Probability Plot zum Vergleich der Referenzschaltung, des Gesamtsystemmodell und des seriellen Modells in 10 Testpunkten des Komparators.

4.2.2.2. Korreliertes System

Als Beispiel für ein korreliertes System wird die zuvor beschriebene Schaltung für einen OTA, bestehend aus Beta-Multiplier, Bias-Netzwerk und OTA, betrachtet. Für die SPM-Entwicklung wird das System in zwei Subsysteme aufgeteilt, wobei der Beta-Multiplier das erste Subsystem darstellt und das zweite aus dem Bias-Netzwerk und dem OTA besteht (Abbildung 4.1). Somit hat das Bias-OTA-Verhaltensmodell neben den Operationsbedingungen Temperatur T und Versorgungsspannung V_{dd} einen zusätzlichen Eingangsparameter V_{ref} . Durch die Berücksichtigung von T und V_{dd} sowie der Alterung t_{age} wird hier ein vollständiges stochastisches PVTA-Verhaltensmodell generiert.

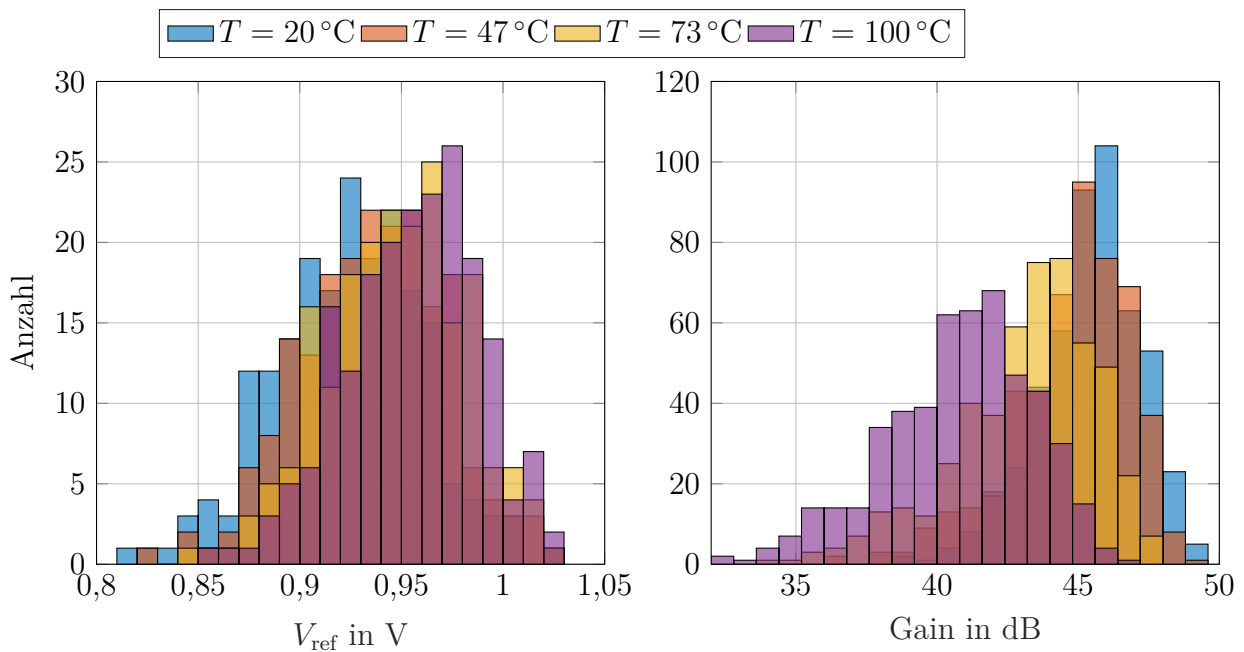


Abbildung 4.12.: Verschiebung der Verteilung der Referenzspannung V_{ref} sowie der Verstärkung (Gain) bei verschiedenen Temperaturen.

Um die Bedeutung der Betrachtung der Verschiebung der Performanceverteilungen über die Betriebsparameter noch einmal hervorzuheben, sind die Verteilungen von V_{ref} sowie der Verstärkung (Gain) des OTA über verschiedene Temperaturen in Abbildung 4.12 dargestellt. Es ist zu erkennen, dass sich der Mittelwert der Verteilung von V_{ref} über verschiedene Temperaturen leicht verschiebt, die Form der Verteilung aber nahezu gleich bleibt. Für den OTA hingegen ändert sich die Verteilung der Verstärkung dramatisch, wobei der Mittelwert für höhere Temperaturen niedriger und die Verteilung breiter wird, während sie immer noch eine Normalverteilung repräsentiert. Dieses Verhalten kann durch die vorgeschlagene Modellierungsmethode gut erfasst werden.

Die Korrelation zwischen den Performances V_{ref} und Verstärkung der beiden Subsysteme wird durch Berechnung des Korrelationskoeffizienten aus einer Monte-Carlo-Simulation unter Nominalbedingungen bei $V_{dd} = 1\text{ V}$ und $T = 25^\circ\text{C}$ bewertet. Die Verstärkung des OTA und die Referenzspannung V_{ref} sind im Nominalpunkt mit $\rho = -0,85$ korreliert. Somit muss für das gesamte System der in Fall II beschriebene Modellierungsansatz angewendet werden.

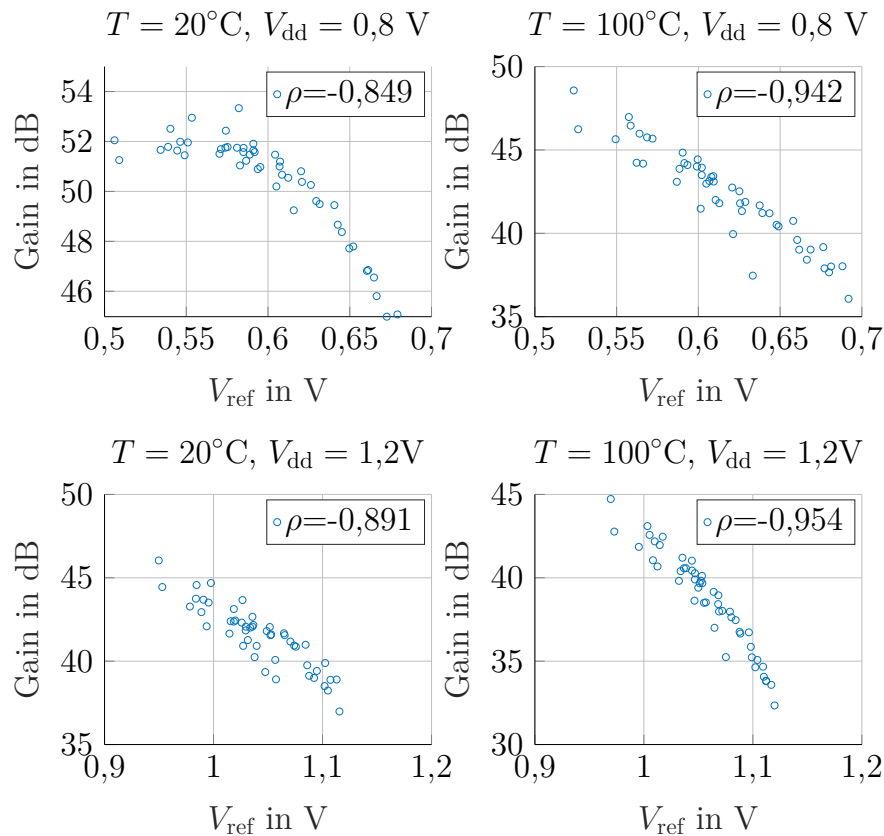


Abbildung 4.13.: Streudiagramme (scatter plots) für die Korrelation zwischen der Referenzspannung V_{ref} des Beta-Multipliers und der Verstärkung (Gain) des OTA.

Anschließend wird analysiert, ob sich die Korrelation für verschiedene Betriebsbedingungen ändert. Die Streudiagramme bei verschiedenen Bedingungen sind in Abbildung 4.13 dargestellt. Da die Korrelation eine nicht zu vernachlässigende Veränderung über die Betriebsbedingungen zeigt, wird die Verschiebung des Korrelationskoeffizienten ebenfalls mit einem RSM modelliert.

Erstellung des stochastischen Performancesmodells

Es werden drei verschiedene Modelle für das OTA-System generiert: 1) ein vollständiges Gesamtsystemmodell, 2) ein hierarchisches Modell mit σ -Korrektur (Fall II) und 3) eines ohne die Korrektur zum Vergleich. Die spezifizierten Parameterbereiche für das Modell sind gegeben durch $V_{\text{dd}} = \{0,8 \dots 1,2\}$ V, Temperatur $T = \{20 \dots 100\}$ °C, und Alter $t_{\text{age}} = \{0 \dots 1e7\}$ s. So wird ein vollständiges PVTA-SPM erzeugt. Das hierarchische Modell besteht aus den beiden Teilen, die in Abbildung 4.1 dargestellt sind.

Die Referenzspannung V_{ref} und die Verstärkung können beide mit Normalverteilungen approximiert werden, was für die Anwendung der σ -Korrektur eine Notwendigkeit ist. Zur Modellierung der Verschiebung der Verteilungen werden die entsprechenden RSMs erzeugt. Die Modellierung des Beta-Multiplier wurde bereits in 4.2.1 gezeigt, hier wird ein neues Modell mit den oben genannten Parametern erzeugt. $\mu_{V_{\text{th}}}$ wird durch eine quadratische RSM dargestellt, während $\sigma_{V_{\text{th}}}$ durch eine Gaußsche radiale Basisfunktion modelliert wird. Die Veränderung über Tempe-

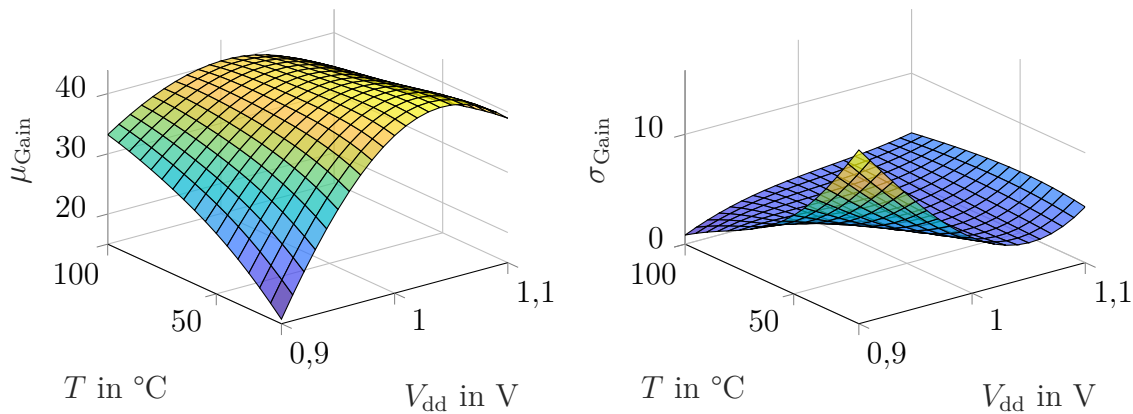


Abbildung 4.14.: RSMs für den Mittelwert μ und die Standardabweichung σ des Subsystems Distributionsnetzwerk und OTA über der Temperatur und dem Widerstand.

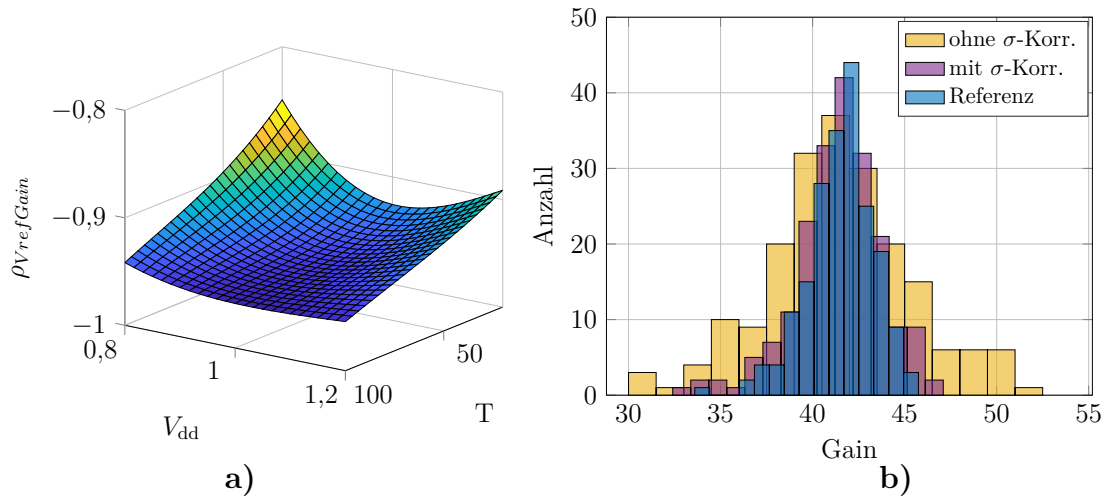


Abbildung 4.15.: a) RSM des Korrelationskoeffizienten $\rho_{V_{bias}Gain}$ und b) Vergleich des hierarchischen Modell mit (w) und ohne (wo) σ -Korrektur und der Referenzschaltung.

ratur und Versorgungsspannung kann auch der Abbildung 3.7 entnommen werden. Für die Verstärkung können sowohl der Mittelwert μ_{Gain} als auch die Standardabweichung σ_{Gain} am genauesten mit radialen Basisfunktionen abgebildet werden. Die RSMs sind in Abbildung 4.14 dargestellt.

Ein zusätzliches RSM wird erstellt, um die Verschiebung des Korrelationskoeffizienten ρ zu modellieren. Dieses ist in Abbildung 4.15a) über der Temperatur und der Versorgungsspannung dargestellt. Das resultierende RSM basiert auf einigen wenigen Gesamtsystem-Simulationen an dedizierten Abtastpunkten, um die Korrelation bestimmen zu können. Die Korrelation verändert sich bei verschiedenen Parameterkombinationen zwischen $\rho \approx -0,849$ und $\rho \approx -0,954$.

Die Standardabweichung für die Verstärkung des hierarchischen OTA-Verteilungsmodells wird innerhalb der Verhaltensbeschreibung gemäß (3.34) neu berechnet. Wie in Abbildung 4.15 zu

sehen ist, lässt die Korrektur von σ die Verteilung schmaler werden, sodass sie die Verteilung der Referenzschaltung besser repräsentiert.

Tabelle 4.2.: Parameterwerte der durch Latin-Hypercube Sampling erstellte Testpunkte für den OTA .

	TP1	TP2	TP3	TP4	TP5	TP6	TP7	TP8	TP9	TP10
T [°C]	49.71	23.65	36.12	62.27	69.29	88.53	56.24	31.51	97.85	78
V_{dd} [V]	1.02	1.07	1.19	1.09	0.99	1.15	0.89	0.805	0.84	0.94
A [$\cdot 10^6$ s]	9.13	6.59	2.89	8.56	3.69	4.59	7.17	1.59	0.61	5.64

Insgesamt wurden zehn Testpunkte ausgewertet, welche in Tabelle 4.2 aufgelistet sind. Abbildung 4.16 zeigt die Verteilung der Verstärkung für die SBMs an verschiedenen Testpunkten im Vergleich zu den Ergebnissen der Simulation der ursprünglichen Referenzschaltung auf Transistorebene. In Abbildung 4.16a) sind die Ergebnisse der hierarchischen SBMs mit und ohne σ -Korrektur dargestellt. Wie bereits erwähnt, zeigt das SBM, das die Korrelation berücksichtigt, eine signifikante Verbesserung der Modellgenauigkeit. Trotz der Verbesserung der Repräsentation der Verteilung durch die Korrektur verbleibt ein Modellierungsfehler im Vergleich zu den Ergebnissen der Referenzschaltung. Dies ist insbesondere bei den Testpunkten TP2 und TP3 zu beobachten, bei denen die Verteilung der Referenzschaltung sehr schmal ist. Ein Vergleich zwischen dem vollständigen Systemmodell und dem SBM mit σ -Korrektur ist in 4.16b) dargestellt und zeigt eine leichte Abweichung der Modellergebnisse aufgrund des hierarchischen Ansatzes. Die Variation wird durch das Modell korrekt approximiert. Ein Testpunkt (TP9), dessen Temperatur am Rande des definierten Parameterbereichs liegt, zeigt für beide Modelltypen eine leichte Abweichung von der Referenz.

Abbildung 4.17 zeigt die Systemzuverlässigkeit R_{sys} für den OTA für alle zehn Testpunkte. Für die Verstärkung wurden beispielhafte Spezifikationsgrenzen zwischen 35 dB und 55 dB gewählt. Die Ergebnisse sind über die Anzahl der in der Monte-Carlo-Analyse verwendeten Simulationspunkte aufgetragen. Das σ -korrigierte hierarchische Modell (Fall II) zeigt eine ähnlich gute Modellierung im Vergleich zum vollständigen Systemmodell. Das Modell ohne σ -Korrektur konvergiert zu falschen Werten für R_{sys} , was zu einer Fehleinschätzung der Systemzuverlässigkeit führt.

Abschließend wird für das hier erstellte stochastische Verhaltensmodell die benötigte Rechenzeit zur Durchführung der Monte-Carlo-Analysen bestimmt. Dafür wird die benötigte Simulationszeit für 100 MC-Simulationen für die Ausführung in einem Thread in Tabelle 4.3 verglichen. Die Simulationen werden auf einem 12-Kern Intel XEON mit 2.2 GHz und 512GB RAM ausgeführt. Die Referenzschaltung (Transistorebene) der OTA-Schaltung und das Verilog-A-Modell des Gesamtsystems werden im Spectre Simulator von Cadence Virtuoso simuliert. Das Verhaltensmodell mit σ -Korrektur wird zudem in MATLAB ausgewertet. Es ist zu erkennen, dass die Simulationszeit für die Schaltungssimulation mit dem SBM drastisch reduziert wird (76,7x). Die Auswertung des SPM in MATLAB ergibt einen Speedup von 334x, was die Fähigkeit zur schnellen Auswertung auf abstrakter Systemebene mit dem vorgestellten Modellierungsansatz zeigt.

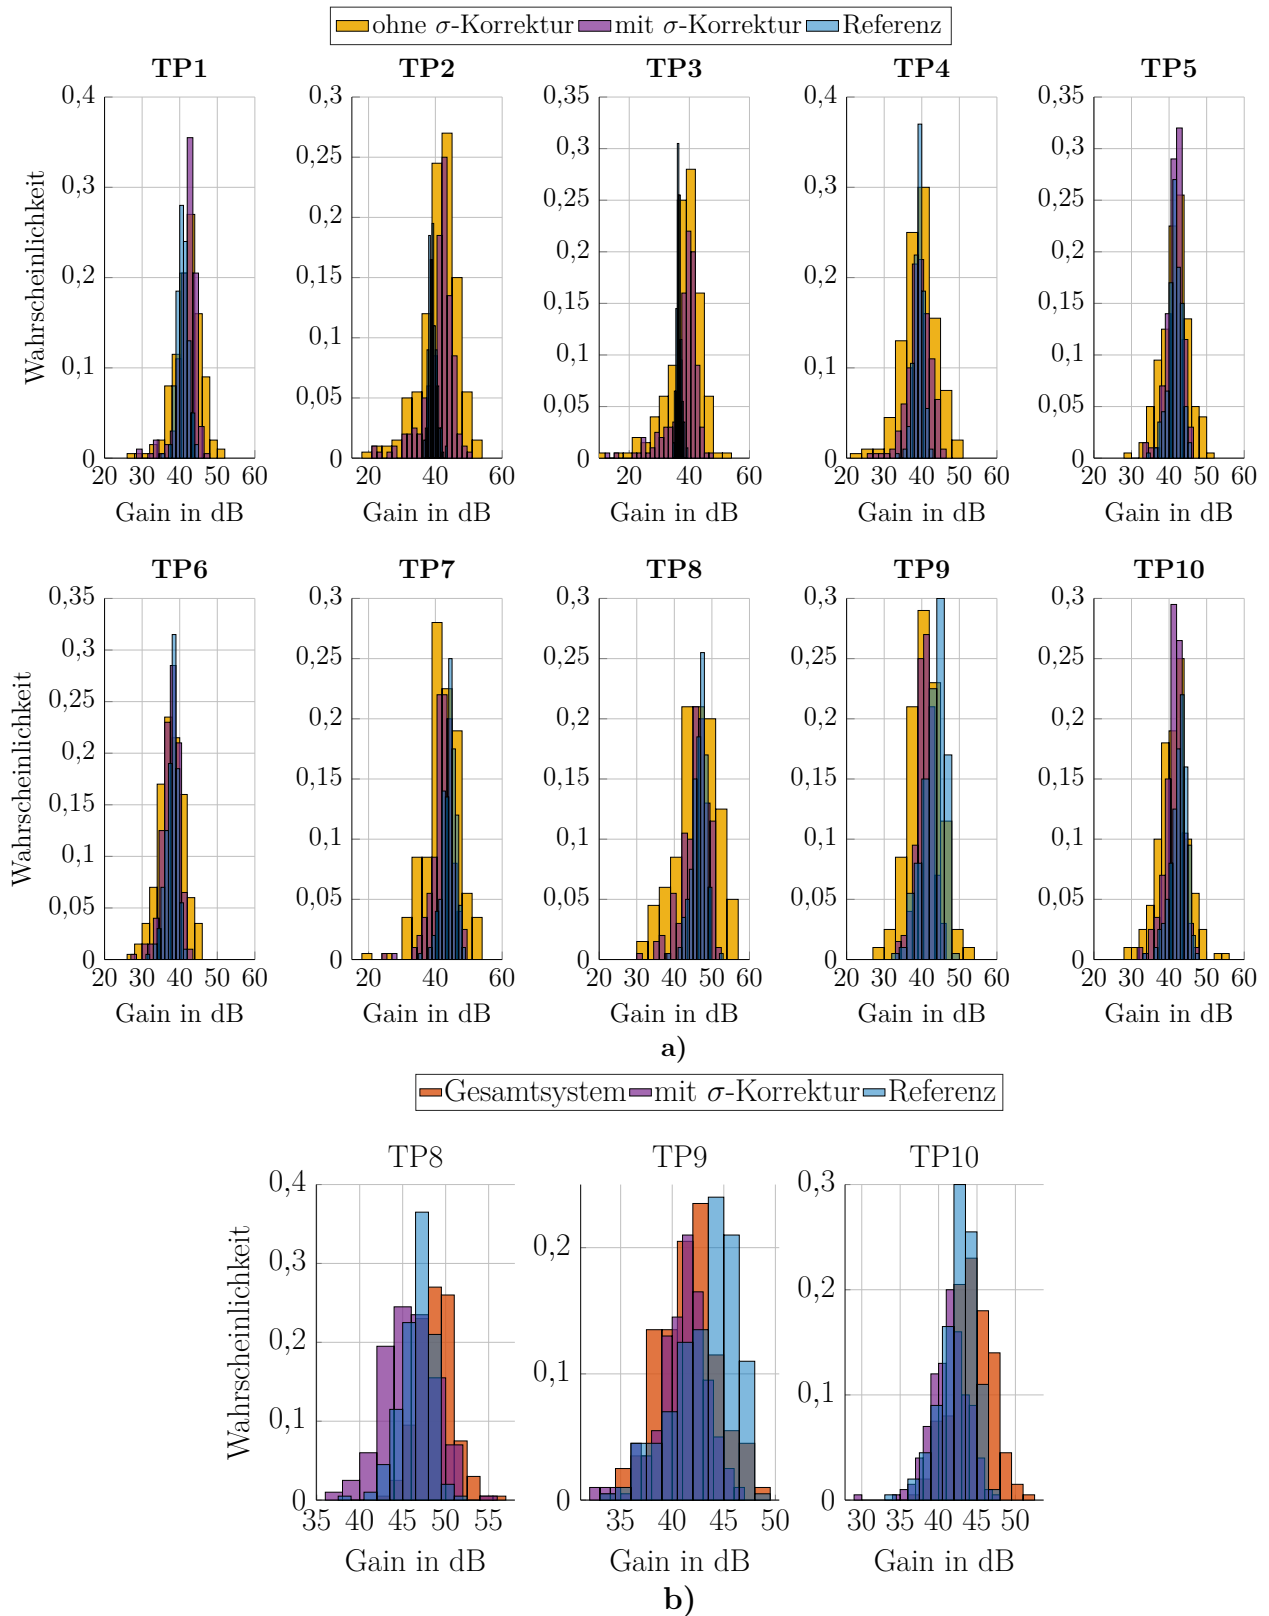


Abbildung 4.16.: Vergleich zwischen den Simulationsergebnissen der Referenzschaltung auf Transistorebene und a) dem hierarchischen OTA SBM mit und ohne σ -Korrektur sowie b) dem Gesamtsystemmodell und dem hierarchischen Modell mit σ -Korrektur an verschiedenen Testpunkten.

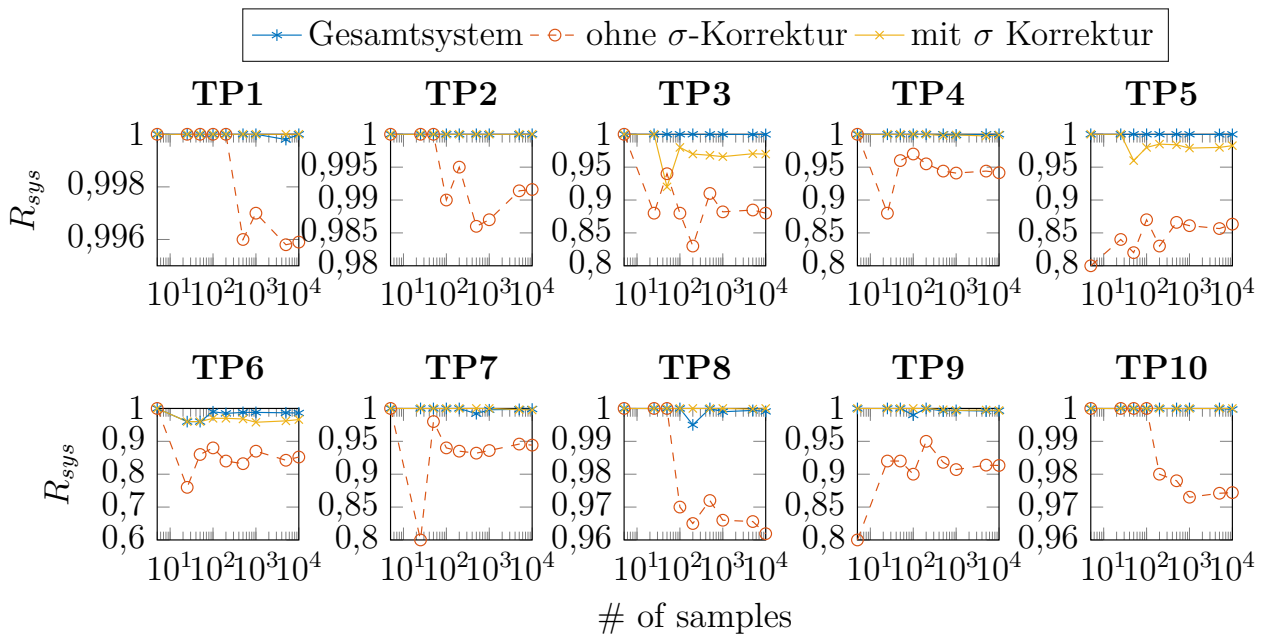


Abbildung 4.17.: R_{sys} für den OTA bei Spezifikationsgrenzen von $35 \text{ dB} < \text{gain} < 55 \text{ dB}$ über die Anzahl an Samples.

Tabelle 4.3.: Vergleich der Simulationszeit von 100 MC-Simulationen bei *single thread execution*.

	Referenz (spectre)	Gesamtsystem Verilog-A	hier. mit σ -Korrektur MATLAB
t_{sim} in s	890	11.6	2.66

4.3. Stochastische Verhaltensmodelle nicht-normaler Verteilungen

Wie zuvor beschrieben, wurden für nicht-(log-)normale Verteilungen zwei Modellierungsmöglichkeiten basierend auf einer Kerndichteschätzung oder Gaussian Mixture Models entwickelt. Zum einen kann ein LUT-basierter Modellierungsansatz genutzt werden, bei dem die Koeffizienten der Verteilungsfunktion gespeichert werden. Bei der zweiten Variante wird die Verteilungsfunktion durch ein RSM modelliert. Im Folgenden wird für beide Varianten das Beispiel des bereits beschriebenen Common-Source-Verstärkers in einer kommerziellen 65-nm-CMOS-Technologie betrachtet.

4.3.1. LUT-basiertes Modell

In Abbildung 4.18 ist die Verteilung der Verstärkung des Common-Source-Verstärkers bei verschiedenen Betriebsbedingungen für variierende V_{dd} bei $T = 50 \text{ }^\circ\text{C}$ dargestellt. Die Verteilung variiert für verschiedene Spannungen V_{dd} und zeigt darüber hinaus ein starkes nicht-




Abbildung 4.18.: Vergleich zwischen Referenz, GMM PDF und Gaußverteilung bei verschiedenen Versorgungsspannungen $V_{dd} = \{0,9, 1, 1,1\}$ V bei $T = 50$ °C.




Abbildung 4.19.: Vergleich der Referenz-CDF mit Gaußverteilung und GMM PDF bei verschiedenen Versorgungsspannungen.

normalverteiltes Verhalten und kann somit nicht ausreichend genau durch eine Normal- oder Lognormalverteilungen beschrieben werden. Um dies hervorzuheben, werden die ebenfalls in 4.18 gezeigten Normalverteilungen anhand der MC-Simulationsdaten berechnet, um die großen Abweichungen zu zeigen, die durch die Annahme einer Normalverteilung entstehen. Die kumulative Dichtefunktion (CDF) in Abbildung 4.19 zeigt ebenfalls die große Abweichung der Normalverteilung von der tatsächlichen Verteilung, während die Variation durch das GMM gut modelliert wird.

Für die Erstellung des LUT-basierten stochastischen Modells wird die Variation der Verstärkung bei verschiedenen Betriebsbedingungen analysiert: $V_{dd} = \{0,9; 1; 1,1\}$ V und $T = \{0, 25, 50, 75, 100\}$ °C. 500 MC-Simulationen werden für jede Bedingung durchgeführt, um die Performanceverteilung zu erfassen. Anschließend wird eine Modellanpassung eines GMM mit sechs Komponenten (Gauß-Kernen) durchgeführt. Die resultierenden Koeffizienten werden

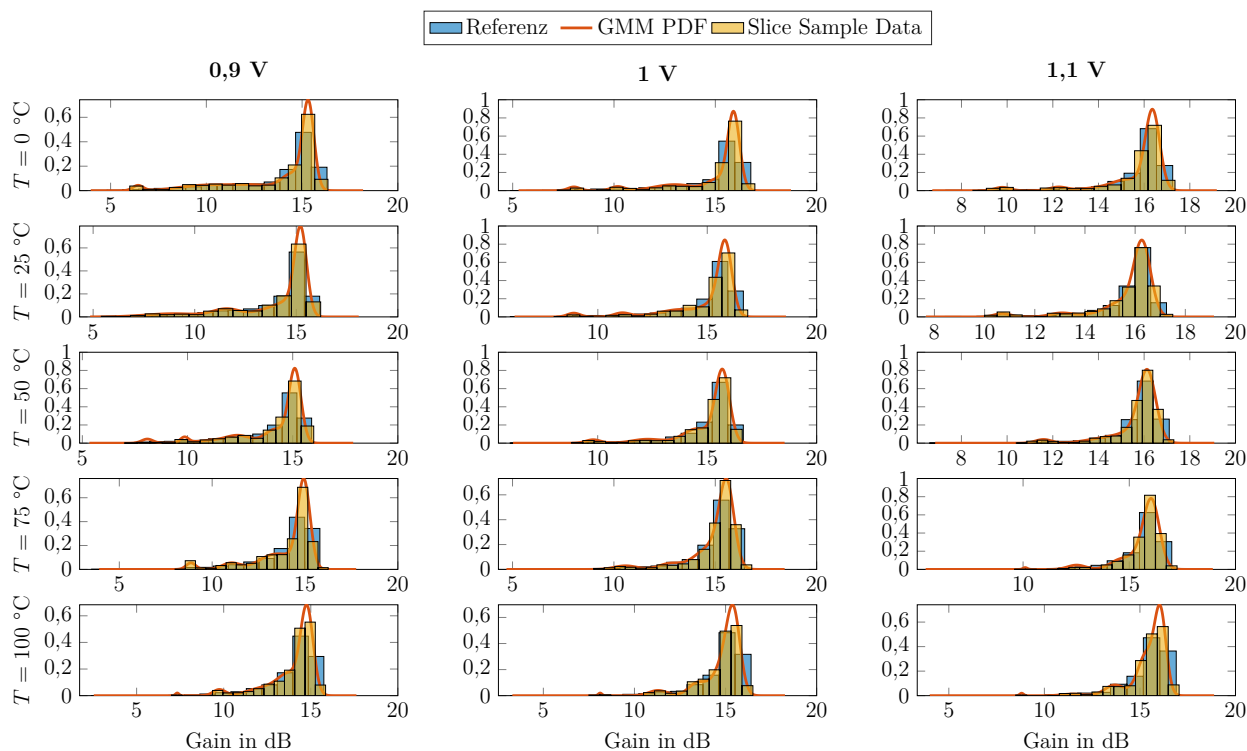


Abbildung 4.20.: Vergleich der Histogramme der Referenz-Verteilung, der durch GMM ermittelten PDF sowie der Ergebnisse des Slice-Sampling.

extrahiert und in einer LUT gespeichert. Anschließend wird die PDF-Gleichung in ein MATLAB-Verhaltensmodell integriert, welches die Koeffizienten aus der LUT ausliest. In diesem Fall wird das Verhaltensmodell nicht auf SPICE-Ebene simuliert, sondern die abstrakte Modellierung in MATLAB betrachtet.

Bei der anschließenden Simulation des Modells werden mithilfe des beschriebenen Slice-Sampling Algorithmus Zufallsstichproben erzeugt, die der Verteilung bei bestimmten, in der LUT definierten, Betriebsbedingungen folgen.

Zum Vergleich und zur Bewertung der Modellgenauigkeit werden 1000 MC-Simulationen für jeden Betriebszustand des Common-Source-Verstärkers (im Folgenden als „Referenz-Verteilung“ bezeichnet) durchgeführt und mit jeweils 1000 durch Slice-Sampling gewonnenen Zufallszahlen des Verhaltensmodells verglichen. In Abbildung 4.20 sind die Histogramme der MC-Simulationen der Referenz-Verteilung im Vergleich zur approximierten PDF und zu den Ergebnissen des Slice Samplings der mit dieser approximierten PDF erstellten Modelle dargestellt. Um die Ergebnisse besser vergleichen zu können, sind die (empirischen) CDFs in Abbildung 4.21 dargestellt. Es ist zu erkennen, dass die Verteilung insgesamt gut durch das GMM beschrieben wird und dass das Slice Sampling eine entsprechende Zufallsstichprobe erzeugt, die dieser Verteilung folgt.

Die CDF-Diagramme für alle in der LUT gespeicherten Betriebsbedingungen sind in Abbildung 4.21 dargestellt und mit den Ergebnissen der dazugehörigen Referenz-Verteilung verglichen. Die Modellierung zeigt gute Ergebnisse für die nicht-normalen Verteilungen. In den Grafiken wird zudem die Verschiebung der Verteilung aufgrund der unterschiedlichen Betriebsbedingungen für T und V_{dd} deutlich.

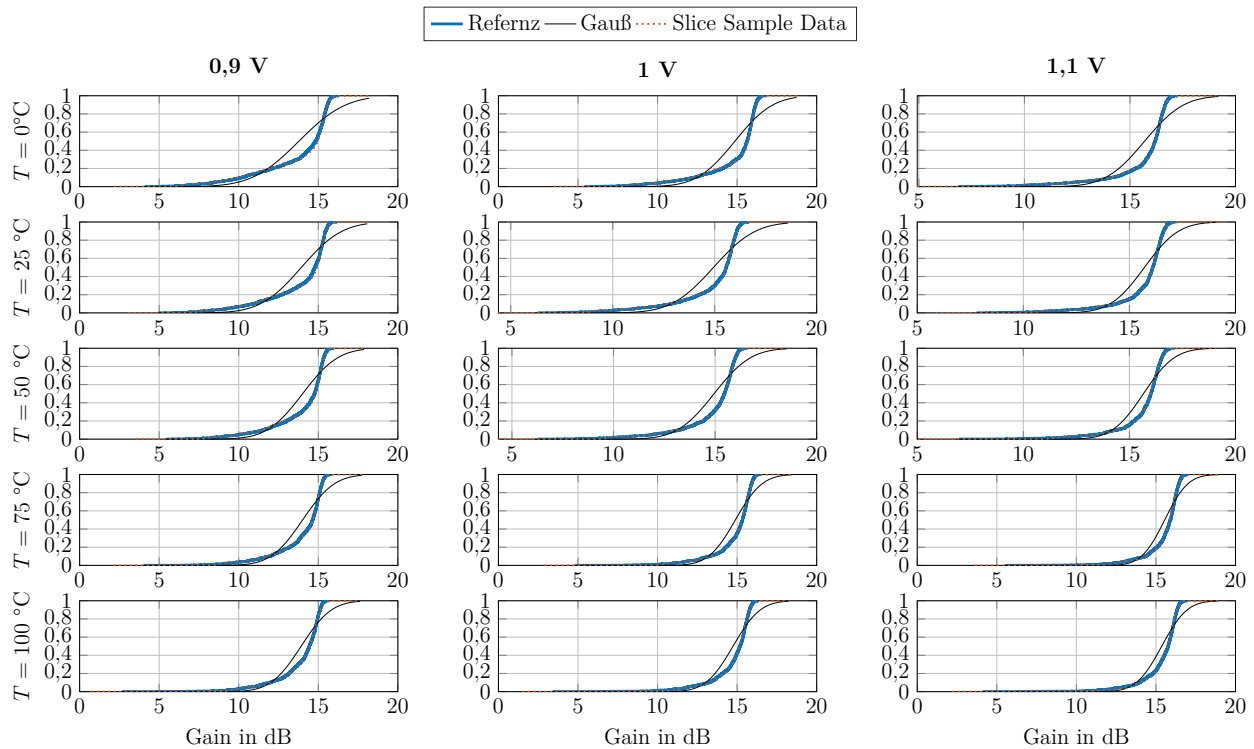


Abbildung 4.21.: Vergleich der CDF der Referenz-Verteilung und des GMM bei unterschiedlichen Betriebsbedingungen.

Die Verteilungen werden zusätzlich mit Hilfe eines Kolmogorov-Smirnov-Tests mit zwei Stichproben und einem Vertrauensniveau von 1 % verglichen. Dabei ergibt sich bei allen Testpunkten, dass eine Übereinstimmung der Wahrscheinlichkeitsverteilungen vorliegt. Bei einem Vertrauensniveau von 5% schlägt der Test bei drei Testpunkten fehl. Eine Erklärung für die Abweichung liegt in der Tatsache, dass es sich bei dem GMM um eine Approximation handelt, die auch aufgrund der Verwendung von sechs Komponenten in ihrer Genauigkeit begrenzt ist. Zudem wurden für die Modellierung und Berechnung der GMM eine MC-Simulation mit 500 Punkten verwendet. Für den hier gezeigten Vergleich wurden mithilfe des erstellten Modells 1000 MC-Punkte erzeugt und mit dem Ergebnis einer MC-Simulation mit ebenfalls 1000 Punkten der Referenzschaltung verglichen. Aufgrund des größeren Umfangs kann es zu Abweichungen kommen, da die Verteilung durch die größere Stichprobe deutlich genauer dargestellt ist.

Ein Nachteil dieses LUT-basierten Ansatzes ist, dass das daraus resultierende Modell lediglich in den für die Modellierung herangezogenen Stützpunkten (Betriebsbedingungen) gültig ist. Eine mögliche Erweiterung, die untersucht werden kann, ist die Verwendung von Interpolation der Koeffizienten zwischen den Stützpunkten. Dies wird womöglich durch die Tatsache erschwert, dass alle drei Parameter des GMM für den jeweiligen Fall optimal gewählt werden und sich somit von Stützpunkt zu Stützpunkt unterscheiden. Das im nächsten Abschnitt vorgestellte RSM-basierte Modell ermöglicht dagegen auch eine Modellierung zwischen den Stützpunkten.




Abbildung 4.22.: RSM der Verstärkungsverteilung des CS-Verstärkers über der Temperatur.

4.3.2. RSM-basiertes Modell

Für die Erstellung eines Modells, welches eine kontinuierliche Modellierung der nicht-normalen Wahrscheinlichkeitsdichte ermöglicht, wird ein RSM-basiertes Modell berechnet. Auch hier wird der Common-Source-Verstärker als Beispiel genutzt.

Die durch das KDE oder GMM gefundene PDF muss für die Modellierung mittels RSM abgetastet werden, um die Stützpunkte zu erhalten. Um eine möglichst genaue Modellanpassung zu ermöglichen, werden neben äquidistanten Stützpunkten auch die Maxima der PDF bestimmt und an diesen Stellen Stützpunkte gesetzt. Somit wird sichergestellt, dass diese entsprechend gut im Modell abgebildet werden.

In diesem Beispiel wird die zuvor genutzte Common-Source-Verstärkerschaltung mit dem in Kapitel 3 beschriebenen RSM-Ansatz modelliert, wobei für die Bestimmung der PDF der KDE-Ansatz verwendet wird. Die Berechnung der KDE erfolgt hier auf Basis von MC-Simulationen mit einem Umfang von 500 MC-Punkten. Die Verstärkung des Verstärkers wird in Abhängigkeit von der Temperatur $T = \{0.. 100\}$ °C und der Versorgungsspannung $V_{dd} = \{0,9.. 1,1\}$ V modelliert. Das resultierende RSM für die Verteilung der Verstärkung ist in den Abbildungen 4.22 und 4.23 dargestellt. Aufgrund der stark nichtlinearen Form gibt es einige Abweichungen in den Zwischenräumen der Stichprobenpunkte. Zur Modellierung der Verteilung wird eine Matérn-2-Regressionsfunktion verwendet. Insbesondere bei der Verteilung über die Versorgungsspannung V_{dd} sind einige Unregelmäßigkeiten erkennbar. Mit den verfügbaren RSM-Funktionen handelt es sich hierbei um die genaueste Anpassung an die vorhandenen Datenpunkte.

Das Modell wird sowohl in den Stützpunkten als auch in Testpunkten für Betriebsbedingungen ausgewertet, die nicht genau den für die Modellerstellung verwendeten Stützpunkten entsprechen. Die Ergebnisse in den Abbildungen 4.24 4.25 zeigen, dass die Approximation in den




Abbildung 4.23.: RSM der Verstärkungsverteilung des CS-Verstärkers über der Versorgungsspannung.




Abbildung 4.24.: Vergleich der CDF von 1000 MC-Simulationen in 5 verschiedenen Stützpunkten.

Stützstellen besser ist. Die Verteilung ist jedoch immer noch gut repräsentiert, insbesondere im Vergleich zu einer Gauß-Verteilung, die an dieselben Daten angepasst wurde.

Wie bereits beschrieben, ist diese Form der Modellierung lediglich für Abschätzungen der zu erwartenden Verteilung anwendbar, da die stochastischen Eigenschaften und Nebenbedingungen nicht berücksichtigt werden.




Abbildung 4.25.: Vergleich der CDF von 1000 MC-Simulationen in 4 verschiedenen Testpunkten, bei denen sich die Temperatur von den Stützpunkten unterscheidet.

4.4. Zusammenfassung

In diesem Kapitel wurden die zuvor vorgestellten Modellierungsmethoden zur Erstellung stochastischer Performance- und Verhaltensmodelle anhand von Beispielschaltungen simulationsbasiert analysiert. Dabei erfolgte zunächst die Betrachtung eines Gesamtsystemmodells sowie eines hierarchischen Modells ohne Korrelation. Dabei zeigte sich, dass die Herangehensweise die Verschiebung des Mittelwerts und der Standardabweichung durch RSMs zu modellieren, gute Ergebnisse liefert. Anschließend erfolgte die hierarchische Modellierung eines Systems mit Korrelation zwischen zwei Subsystemen, wobei ein stochastisches PVTA-Verhaltensmodell durch die Berücksichtigung der Veränderung durch Temperatur, Spannung und Alterung erstellt wurde. Dabei konnte die Verbesserung der Genauigkeit durch die σ -Korrektur gezeigt werden. Im letzten Abschnitt wurde eine Beispielschaltung betrachtet, deren Variation nicht normal- oder lognormalverteilt ist und somit durch GMM bzw. KDE modelliert wurde.

Die betrachteten Modellierungsverfahren ermöglichen die Erfassung der Variation der Performances einer Schaltung und ihrer Veränderung über verschiedene Umgebungsparameter und erlauben somit die Betrachtung dieser auf höherer Abstraktionsebene, um bspw. Zuverlässigkeitsanalysen durchzuführen.

Monitoring analoger Schaltungskomponenten

Trotz eines zuverlässigkeitsorientierten Designs integrierter Schaltungen und der Berücksichtigung von Sicherheits-Margins kann es während der Lebensdauer einer Schaltung zu unerwünschten Verschiebungen der Eigenschaften und damit der Performance aufgrund von veränderlichen äußeren Einflüssen sowie alterungsbedingter Degradierung kommen. Insbesondere in sicherheitskritischen Anwendungen ist somit eine Detektion der Degradierung bzw. eine Überwachung des aktuellen Zustandes wünschenswert, um die Funktionalität des Gesamtsystems garantieren und ggf. auf Veränderungen reagieren zu können.

Für die Überwachung bzw. die Ermittlung, ob die gegebenen Spezifikationen eingehalten werden, werden Monitor-Strukturen benötigt, welche anhand von Performance Indikatoren den aktuellen Zustand der Schaltung, respektive die Schaltungseigenschaften bzw. Performancewerte erfassen können.

Ein Verfahren zur Detektion und Korrektur von Fehlern während des Betriebs (on-line) innerhalb eines analogen Sensorsystems durch digitale Kalibration mit adaptiven Filtern wurde in der Arbeit von Sascha Heißen [Hei19] vorgestellt. Dieses Verfahren setzt die Kenntnis des „idealen“ fehlerfreien Ausgangssignals der zu überwachenden Schaltung voraus.

In dem hier entwickelten Monitoring-Konzept wird dieses Verfahren erweitert und in Kombination mit den zuvor beschriebenen RSM-basierten Verhaltensmodellen zur Ermittlung der aktuellen Performances der zu überwachenden Schaltungskomponente verwendet. Dabei werden die Filterkoeffizienten der zur Fehlerkorrektur eingesetzten adaptiven Filter herangezogen und mithilfe des durch die Verhaltensmodelle bekannten idealen Schaltungsverhaltens zur Ermittlung der aktuellen Performance sowie zur Überwachung von Degradation genutzt. Die in dem Verhaltensmodell integrierten RSM-basierten Performancemodelle beschreiben das durch Schaltungssimulationen ermittelte Verhalten der Schaltungsperformances unter verschiedenen Betriebsbedingungen. Diese Modelle werden mit den in Kapitel 3 beschriebenen Verfahren und dem dort vorgestellten MATLAB-Tool ReSeMBleD erstellt.

In diesem Kapitel wird zunächst ein Überblick über bestehende Verfahren zur Funktionsprüfung und Überwachung von Schaltungen gegeben. Anschließend erfolgt eine kurze Betrachtung der Grundlagen adaptiver Filter, welche die Basis des hier vorgestellten Monitoring-Konzepts bilden. Anschließend wird der in dieser Arbeit entwickelte Monitoring-Ansatz vorgestellt.

5.1. Überblick zu Test- und Monitoring-Verfahren

Das in dieser Arbeit entwickelte Verfahren zur Überwachung der aktuellen Schaltungsperformance sowie des Degradationszustands basiert auf der Verwendung des in [Hei19] vorgestellten Verfahrens zur Fehlererkennung und Korrektur mithilfe adaptiver Filterstrukturen. Sowohl für Testverfahren analoger Schaltungen als auch die Überwachung des Degradationszustands existieren eine Vielzahl von Methoden mit unterschiedlichen Anwendungsgebieten und Zielsetzungen. Im Folgenden wird ein kurzer Überblick über die gängigen Verfahren gegeben.

Grundlegend kann zwischen zwei Arten von Tests unterschieden werden: der einmalig durchgeführten Funktionsprüfung einer Schaltung oder eines Chips direkt nach der Produktion und einer zeitweisen oder dauerhaften Überprüfung während des Betriebs, was auch als Monitoring bezeichnet wird. In der Regel soll durch diese Tests ermittelt werden, wie die Performance einer Schaltung bspw. durch Prozessvariation beeinflusst ist und ob sie innerhalb der gegebenen Spezifikationen arbeitet. Die meisten der Testverfahren zielen somit darauf ab, defekte Schaltungen zu identifizieren. Eine genaue Bestimmung der Schaltungsperformances ist nur bei wenigen Verfahren das Ziel. Beim Monitoring erfolgt zudem eine Unterteilung in Offline- und Online-Monitoring [Ary15]. Beim Offline-Monitoring wird die Schaltung zu festgelegten Zeitpunkten mithilfe von Testsequenzen untersucht, während beim Online-Monitoring eine Überwachung während des laufenden Betriebs der Schaltung erfolgt.

Eine der am weitesten verbreiteten Methoden ist das sog. spezifikationsbasierte Testen [SK17], wobei eine Funktionsprüfung direkt nach der Fertigung durchgeführt wird. Dabei werden die charakteristischen Performances der Schaltung direkt gemessen und mit den geforderten Spezifikationen abgeglichen, was hochspezialisiertes Messequipment, das sog. *Automatic Test Equipment* (ATE) erfordert. Diese Art von Tests ist sowohl kosten- als auch zeitintensiv, was durch die zunehmende Komplexität moderner SoC-Designs weiter gesteigert wird.

Aus diesem Grund wird seit langem an Methoden gearbeitet, um das Testen direkt auf dem Chip zu integrieren und zu vereinfachen. Diese werden als Design-for-Test (DFT)-Methoden bezeichnet. Die Teststrukturen sollen dabei möglichst wenig Platz auf dem Chip einnehmen und dürfen die normale Funktionalität nicht negativ beeinflussen. Eine besonders in digitalen Systemen weit verbreitete Methode ist das Built-in-Self-Test (BIST)-Verfahren [Ary15]. Dieses wurde auch für analoge Schaltungen adaptiert [SK17].

Bei BIST-Verfahren wird in der Regel ein durch einen auf dem Chip befindlichen Signalgenerator ein Testsignal in die Schaltung eingespeist und das Ausgangssignal analysiert. Da das Testsignal und die gewünschte Systemantwort bekannt sind, kann so ein Rückschluss auf die Funktionalität bzw. die Performance erfolgen.

Beim Oszillator-basierten Testverfahren wird die zu testende Schaltung durch eine positive Rückkopplungsschleife zu einem schwingungsfähigen System rekonfiguriert [SK17]. Aus der gemessenen Oszillationsfrequenz und -magnitude können Rückschlüsse auf die Schaltungsperformance gezogen werden, da diese maßgeblich von den Prozessparametern und den Elementen des Rückkopplungsnetzwerks abhängen. Dieses Testverfahren ist für eine Vielzahl an Schaltungen anwendbar und benötigt keinen zusätzlichen Signalgenerator wie viele andere BIST-Verfahren, wodurch sich die Komplexität der zusätzlich erforderlichen Testschaltung reduziert.

Im Gegensatz zu diesen Testverfahren, welche die Funktionsprüfung der Schaltung zum Ziel haben, sollen Degradationsmonitore oder Alterungssensoren die Veränderung des Schaltungsverhaltens über der Zeit ermitteln. In der Literatur gibt es bereits verschiedene Ansätze für Degradationsmonitore, wobei generell zwischen integrierten in-situ-Sensoren und Off-Chip-Lösungen unterschieden werden kann. Des Weiteren bestehen Unterschiede bei der Überwachung analoger Komponenten auf der einen und digitaler Schaltungen auf der anderen Seite sowie zwischen den berücksichtigten Alterungsmechanismen. Wie bereits zuvor beschränkt sich die Analyse hier auf die Betrachtung von Sensoren zur Erfassung gradueller Degradation (HCI und BTI) und nicht plötzlich auftretender Ereignisse (EM und TDDDB).

In digitalen Schaltungen führt Alterung zur Veränderung der Signallaufzeiten, was zur Überwachung der Degradation genutzt werden kann. Eine Erhöhung der Verzögerung in den Gattern kann im schlechtesten Fall zu Setup-Hold-Fehlern führen, wenn die Setup- bzw. Hold-Zeiten von Flip-Flops oder Latches verletzt werden. Zum einen können Monitor-Elemente direkt innerhalb des kritischen Pfades eingesetzt werden, so bspw. beim Razor-Verfahren [EKD⁺03]. Dies hat den Vorteil, dass sichergestellt ist, dass die Degradierung direkt überwacht werden kann und die Ergebnisse nicht durch unterschiedliche Stressbedingungen verfälscht werden. Darüber hinaus gibt es Ansätze, bestehende BIST-Verfahren zur Erfassung von Degradation zu verwenden [FYV⁺15, LXM⁺18]. Ein weiterer Ansatz zur Überwachung digitaler Schaltungen basiert auf der Replikation des kritischen Pfades und der Detektion von Laufzeitunterschieden zwischen dem Replikat und dem Original-Pfad [SKY⁺18].

Ein recht weit verbreiteter Ansatz, der sowohl in digitalen als auch analogen Schaltungen Anwendung finden kann, ist die Verwendung von Ringoszillatoren zum Degradationsmonitoring [LJ13, WKK⁺14, TLY⁺12, ITT⁺17, WKK⁺14]. Ein dedizierter Ringoszillator wird für eine bestimmte Zeit Stressbedingungen ausgesetzt, was zu einer Frequenzänderung führt. Aus der Frequenzänderung wird dann durch einen Vergleich mit der Frequenz eines ungealterten Ringoszillators auf die Degradation der Schaltung geschlossen. Dieses Verfahren wird teilweise auch für die zuvor beschriebene Replikation des kritischen Pfades in einer digitalen Schaltung verwendet. Des Weiteren existieren Methoden zur Messung der Schwellspannung, deren Änderung ebenfalls ein Indiz für die Degradierung der Transistoren ist [KWC10].

Ferner existieren spezialisierte Sensoren zur Überwachung individueller Alterungsmechanismen. Dabei werden die Teststrukturen, bei denen es sich wie zuvor um Ringoszillator-Strukturen handeln kann, unterschiedlichen Stressbedingungen ausgesetzt, wodurch die einzelnen Degradationsmechanismen angeregt werden [WKK⁺14]. Diese Art der Messungen benötigen einen hohen zusätzlichen Entwurfsaufwand, sowie Fläche und Energie.

Ein gemeinsamer Nachteil vieler dieser Monitoring-Verfahren ist, dass die Messung bzw. Überwachung der Schaltung indirekt erfolgt, d.h. es werden spezielle Sensoren verwendet, die sich zwar auf dem gleichen Chip befinden, jedoch nicht direkt die Schaltungseigenschaften messen. Dadurch sind die Sensoren anderen Stressbedingungen ausgesetzt als die eigentliche zu überwachende Schaltung, deren Eingangssignale keine Berücksichtigung finden. Zudem kann es durch die örtliche Entfernung auf dem Chip zu einer Abweichung der jeweiligen Prozesscorner kommen. Da jedoch die individuellen Stressbedingungen einen signifikanten Einfluss auf die Alterung haben, kann es zu einer nicht zu vernachlässigen Differenz zwischen der Degradierung des Sensors und der eigentlichen Schaltung kommen [SKY⁺18].




Abbildung 5.1.: Aufbau eines adaptiven Filters (nach [Hay02]). In nachfolgenden Abbildungen wird der Adaptionsalgorithmus nicht mehr separat dargestellt.

5.2. Grundlagen adaptiver Filter

In diesem Abschnitt werden die Grundlagen der adaptiven Filter kurz vorgestellt, die im Zuge des hier vorgestellten Monitoringkonzepts zur Überwachung des Schaltungszustandes verwendet werden. Für eine umfassendere Herleitung sei hier auf [Hei19] und [Hay02] verwiesen.

5.2.1. Adaptive FIR-Filter

Adaptive Filter werden in der digitalen Signalverarbeitung u.a. in der Kanalverzerrung und zur Rauschunterdrückung eingesetzt, wenn ein Signal durch unbekannte Störgrößen verfälscht wird und eine Rekonstruktion nötig ist. Die Möglichkeit der adaptiven Anpassung der Filterkoeffizienten ermöglicht dabei den Umgang sowohl mit konstanten als auch zeitlich veränderlichen Störgrößen.

Adaptive Filter können sowohl analog als auch digital implementiert werden, wobei in dieser Arbeit eine digitale und damit zeitdiskrete Implementierung verwendet wird, welche im folgenden näher erläutert wird. Der grundlegende Aufbau eines solchen digitalen adaptiven Filters ist in Abbildung 5.1 dargestellt.

Ein adaptives Filter in der Signalverarbeitung zeichnet sich dadurch aus, dass die Filterkoeffizienten und damit die Übertragungsfunktion während des Betriebs verändert werden können. Die Funktion des Filters lässt sich dabei grob in zwei Prozesse unterteilen, welche als Rückkopplungsschleife zusammenarbeiten [Hay02]:

1. Im Filterprozess wird das Ausgangssignal des Filters basierend auf dem Eingangssignal und den Filterkoeffizienten sowie das Fehlersignal berechnet.
2. Im Adaptionsprozess erfolgt die Anpassung der Filterkoeffizienten basierend auf dem ermittelten Fehler.

Das Eingangssignal $u[n]$ des Filters ist durch unbekannte Störgrößen fehlerbehaftet. Ziel ist die Minimierung des Differenz- bzw. Fehlersignals e , also des Fehlers zwischen dem gewünschten fehlerfreien Signal d und dem tatsächlich vorliegenden Ausgangssignal des Filters y . Diese




Abbildung 5.2.: Aufbau eines FIR-Filters

Anpassung erfolgt durch einen Adaptionsalgorithmus, welcher die Berechnung der neuen Filterkoeffizienten nach einem bestimmten Fehlermaß vornimmt. Das gewünschte (engl. *desired*) Signal d wird auch als Referenzsignal bezeichnet. Das Fehlersignal $e[n]$ ergibt sich damit zu

$$e[n] = d[n] - y[n]. \quad (5.1)$$

Das Ausgangssignal $y[n]$ des adaptiven Filters ergibt sich aus der Gewichtung des Eingangssignals mit den durch den Adaptionsalgorithmus bestimmten Filterkoeffizienten $\mathbf{w}[n]$. Die Ordnung N des Filters gibt dabei die Länge des Vektors bzw. die Anzahl der Verzögerungselemente an [Hay02]. D.h. die zurückliegenden N Signalwerte des Filtereingangssignals $\mathbf{u}[n]$ werden mit dem Vektor der Filterkoeffizienten $\mathbf{w}[n]$ gewichtet und ergeben somit das Ausgangssignal des Filters:

$$y[n] = \mathbf{w}[n]\mathbf{u}[n] = \sum_{k=0}^N w_k[n]u[n-k] \quad (5.2)$$

Damit beläuft sich die Anzahl der Filterkoeffizienten auf $N + 1$.

Im Rahmen dieser Arbeit wird basierend auf [Hei19] für die Implementierung der Filterfunktion ein digitales Filter mit endlicher Impulsantwort (engl. *Finite Impulse Response Filter*, *FIR-Filter*) verwendet. Diese zeichnen sich durch ihre einfache Implementierbarkeit sowie ihre leichter zu erreichende Stabilität im Vergleich zu Filtern mit unendlicher Impulsantwort (engl. *Infinite Impulse Response Filter*, *IIR-Filter*) aus. Die Struktur eines FIR-Filters ist in Abbildung 5.2 gezeigt.

5.2.2. LMS-Algorithmus

Wie bereits beschrieben, erfolgt die adaptive Anpassung der Filterkoeffizienten mithilfe eines Adaptionsalgorithmus. In der vorliegenden Arbeit wird dabei auf den *Least-Mean-Squares*-Algorithmus (LMS-Algorithmus) zurückgegriffen. Wie in [Hei19] gezeigt wurde, ist dieser Lösungsalgorithmus bezüglich Genauigkeit und Geschwindigkeit gut zur Korrektur der auftretenden Fehler geeignet. Aus diesem Grund wird hier lediglich der LMS Algorithmus zur adaptiven Bestimmung der Filterkoeffizienten verwendet. Der LMS-Algorithmus basiert auf dem Gradientenverfahren (Methode des steilsten Abstiegs) und findet aufgrund seiner ho-

hen Robustheit und einfachen Implementierbarkeit häufig Anwendung. Die Berechnung der Matrixinversion sowie die Bestimmung der Korrelationsfunktion wird hierfür nicht benötigt [Hay02].

Die Update-Gleichung des LMS-Algorithmus zur Bestimmung der Filterkoeffizienten lautet:

$$w_k[n+1] = w_k[n] + \mu_{LMS} \cdot u[n-k]e[n] \quad (5.3)$$

wobei $e[n]$ der Fehler aus Gleichung 5.1 ist. Die Update-Gleichung kann auch in vektorieller Form dargestellt werden:

$$\mathbf{w}[n+1] = \mathbf{w}[n] + \mu_{LMS} \mathbf{u}[n]e[n]. \quad (5.4)$$

Die Schrittweite μ_{LMS} ist entscheidend für die Stabilität des Adaptionsalgorithmus des Filters. Die maximale Schrittweite kann über die mittlere Leistung des Eingangssignals u abgeschätzt werden:

$$\mu_{LMS} < \mu_{LMS,max} = \frac{2}{\|\mathbf{u}[n]\|^2} \quad (5.5)$$

In der Praxis wird die Schrittweite in der Regel deutlich unterhalb dieses maximalen Grenzwertes gewählt, um die Konvergenz des Filters zu gewährleisten.

Als Erweiterung des hier beschriebenen grundlegenden LMS-Algorithmus existieren verschiedene Verfahren zur adaptiven Anpassung der Schrittweite. Diese können zu einer besseren Stabilität des Filters beitragen. In [Hay02] ist ein Verfahren beschrieben, welches eine Adaption in jedem Zeitschritt vornimmt, wobei berücksichtigt wird, dass die zugrundeliegenden stochastischen Prozesse eines Systems nicht bekannt sind. Weitere Verfahren zur adaptiven Schrittweitenanpassung sind beispielsweise in [BCO16] zusammengefasst.

5.3. Monitoring-System

Der in dieser Arbeit entwickelte Monitoring-Ansatz zur Bestimmung von nicht direkt messbaren Schaltungseigenschaften basiert auf der Verwendung des in [Hei19, 17, HHT⁺18a] vorgestellten digitalen Fehlerkorrekturverfahrens. Durch die Kenntnis bekannter Einflussfaktoren wie Temperatur und Versorgungsspannung soll der aktuelle Zustand der Schaltung bzgl. Degradation ermittelt werden, sowie eine Abschätzung der verbleibenden Lebenszeit möglich sein. Zu diesem Zweck werden die Filterkoeffizienten der zuvor beschriebenen adaptiven Filter herangezogen. Dieses System erfordert zudem Kenntnis über das ideale Schaltungsverhalten. Dafür werden die zuvor in dieser Arbeit behandelten RSM-basierten Verhaltensmodelle verwendet.

In der Abbildung 5.3 ist die Struktur des hier entwickelten Monitoring-Ansatzes gezeigt, welcher die Schätzung der aktuellen Performances der untersuchten Schaltung (circuit under test, CUT) ermöglicht. Die Methode beruht auf der Verwendung eines RSM-basierten Verhaltensmodells der Testschaltung, welches zur Bestimmung des Referenzsignals genutzt wird. Durch die Verwendung von RSMs können verschiedene Betriebs- und Umgebungsbedingungen berücksichtigt werden, wodurch das ideale Schaltungsverhalten unter diesen veränderbaren Bedingungen bekannt ist. Um alterungsbedingte Änderungen des Schaltungsverhaltens zu erkennen, müssen die Einflüsse von Prozessvariation (P), Versorgungsspannung (V) und Temperatur (T) bekannt sein und herausgerechnet werden. Der Einfluss durch Prozessvariation kann durch einmalige Kalibra-

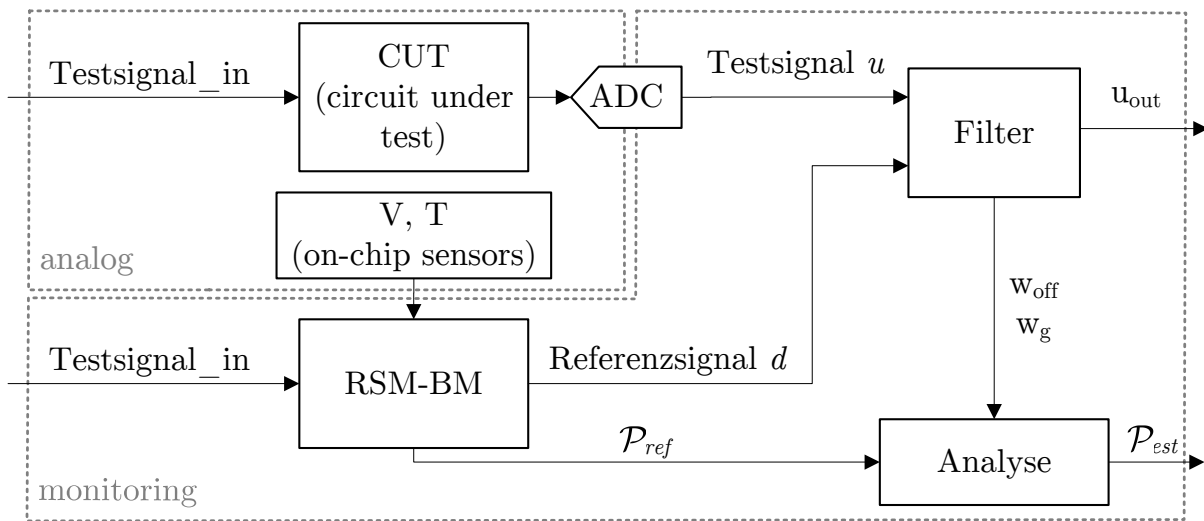


Abbildung 5.3.: Ablauf des Monitoring zur Bestimmung der Schaltungsperformance.

tion der Schaltung vor Inbetriebnahme bestimmt werden. Die aktuellen Umgebungsdaten wie Temperatur und Versorgungsspannung werden dabei von Sensoren (on- oder off-Chip) erfasst. Die RSMs berechnen die unter den gemessenen Bedingungen idealen zu erwartenden Referenzperformances \mathcal{P}_{ref} der Schaltung. Das damit ermittelte Referenzsignal wird für die Korrektur des Fehlers im Testsignal durch adaptive Filter genutzt. Zusammen mit den resultierenden Filterkoeffizienten werden die Referenzperformances zur Analyse und Bestimmung der aktuellen Performance des CUT verwendet. Im Folgenden werden die einzelnen Bestandteile des Monitors näher erläutert.

Das Testsignal kann entweder wie in [Hei19] auf das Nutzsignal aufmodelliert werden, um somit ein Online-Monitoring während des Betriebs zu ermöglichen. Zur Überwachung von Alterung ist es ausreichend, Testzyklen in größeren Zeitabständen durchzuführen, da Alterung erst auf einer größeren Zeitskala messbar ist. Die folgenden Ergebnisse basieren auf der Nutzung des offline-Monitoring-Ansatzes.

Das Monitoring durch die adaptiven Filter erfolgt in einer digitalen Schaltung, sodass die analogen Signale des CUT zunächst durch einen ADC gewandelt werden. Das für das Monitoring benötigte Testsignal muss von einer geeigneten Signalquelle erzeugt werden, deren Realisierung hier nicht betrachtet wird. Eine Implementierung einer Sinussignalquelle ist bspw. in [BVR11] gezeigt. Für die Erstellung des Referenzsignals im digitalen Schaltungsteil kann ein, oder eventuell auch mehrere, Testeingangssignal vor dem Betrieb der Schaltung abgespeichert werden.

5.3.1. Adaptive Filterstruktur

Die zur Detektion und Korrektur der auftretenden Offset- und Verstärkungsfehlern verwendete adaptive Filterstruktur ist in Abbildung 5.4 dargestellt. Der Aufbau der Filter ist aus [Hei19] übernommen. Dabei werden zwei kaskadierte adaptive Filter verwendet, um zunächst eine Kor-

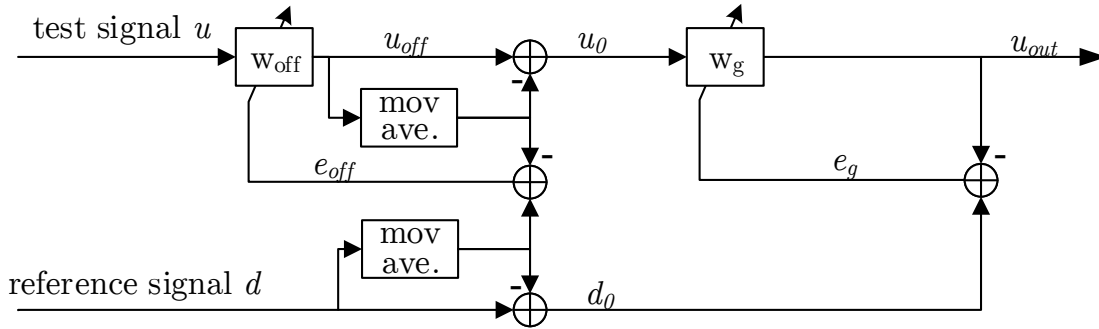


Abbildung 5.4.: Kaskadierte adaptive Filter zur Bestimmung des Offset- und Verstärkungsfehlers (Korrektur: error off positiv)

rektur des Offset-Fehlers und darauffolgend des Verstärkungs-Fehlers durchzuführen. Für die Bestimmung der Filterkoeffizienten wird hier der LMS-Algorithmus verwendet. Der prinzipielle Ansatz des präsentierten Monitoring-Verfahrens ist jedoch unabhängig vom gewählten Filteralgorithmus, dieser kann entsprechend den Gegebenheiten angepasst werden. In [Hei19] wurden zusätzlich der NLMS- und RLS-Algorithmus untersucht. Das Korrekturverfahren kann sowohl statische als auch dynamische Offset- und Verstärkungsfehler ermitteln. Für die Gleichungen zur Bestimmung der Filterkoeffizienten und des Filterausgangssignal wird hier die in [Hay02] verwendete Definition herangezogen.

Offset-Fehler

Der Offset-Fehler ist additiv und kann daher folgendermaßen mithilfe der Koeffizienten des adaptiven Filters W_{off} korrigiert werden:

$$u_{off}[n] = u[n] + \sum_{k=0}^{N-1} w_{off,k}[n]. \quad (5.6)$$

Zur Bestimmung des Offset-Fehlers und der Berechnung der Filterkoeffizienten wird der Mittelwert des Test- und Referenzsignals benötigt. Dazu wird ein gleitender Mittelwert (*moving average*) verwendet, welcher die letzten n Signalwerte zur Berechnung des Mittelwerts heranzieht. Das Fehlersignal ergibt sich damit zu

$$e_{off}[n] = \bar{d}[n] - \overline{u_{off}}[n] \quad (5.7)$$

wobei $\bar{\square}$ die gleitenden Mittelwerte des Testsignals u und Referenzsignals d bezeichnet.

Wie in [Hei19] beschrieben, wird eine anhand des *Vorzeichen-LMS-Algorithmus* [MH00] angepasste Gleichung zur Bestimmung der Filterkoeffizienten genutzt, um das Vorliegen eines Mittelwertes und das Vorzeichen zu berücksichtigen:

$$\mathbf{w}_{off}[n+1] = \mathbf{w}_{off}[n] + \text{sgn}(u)\mu_{off}\mathbf{u}[n]e_{off}[n] \quad (5.8)$$

Als Startwert werden die Filterkoeffizienten zu null gesetzt.

Verstärkungsfehler

Für die Bestimmung des Verstärkungsfehlers ist ein mittelwertfreies Signal nötig. Zu diesem Zweck werden die zuvor berechneten gleitenden Mittelwerte vom Testsignal als auch vom Referenzsignal subtrahiert, wodurch ein mittelwertfreies Testsignal u_0 und Referenzsignal d_0 erzeugt wird. Anschließend wird der multiplikative Verstärkungsfehler mithilfe eines weiteren adaptiven Filters korrigiert:

$$u_{out}[n] = \mathbf{w}_g[n] \mathbf{u}_0 = \sum_{k=0}^{N-1} w_{g,k}[n] u_0[n-k] \quad (5.9)$$

Auch hier erfolgt die Berechnung der Filterkoeffizienten mithilfe des LMS-Algorithmus:

$$\mathbf{w}_g[n+1] = \mathbf{w}_g[n] + \mu_g \mathbf{u}_0[n] e_g[n] \quad (5.10)$$

wobei der Fehler durch

$$e_g[n] = d_0[n] - u_{out}[n] \quad (5.11)$$

gegeben ist. Die Korrektur des Verstärkungsfehlers durch das adaptive Filter W_g erfolgt erst, nachdem die Korrektur des Offset-Fehlers erfolgreich war, d.h. nachdem e_{off} eine Fehlergrenze unterschreitet. Dies stellt sicher, dass durch das Filter lediglich Verstärkungsfehler und nicht etwaige überlagerten Offset-Fehler korrigiert werden. Der Startwert für die Koeffizienten w_g wird in diesem Fall aufgrund des multiplikativen Fehlers zu eins gewählt.

Wie die vorausgegangene Arbeit in [Hei19] gezeigt hat, ist die Verwendung eines Filters der Ordnung 0 mit lediglich einem Filterkoeffizienten ausreichend, um eine ausreichend schnelle und genaue Korrektur der auftretenden Fehler zu erreichen. Die Verwendung eines Filterkoeffizienten pro Filter ist zudem im Bezug auf die Verwendung des Filters als Monitor hilfreich. In diesem Fall ist der letztendlich erreichte Filterkoeffizient gleich dem Fehler im Signal, sodass die Koeffizienten zur Bestimmung der aktuellen Performance genutzt werden können. Damit ergeben sich für die Ausgangssignale der Filter folgende Zusammenhänge:

$$u_{off}[n] = u[n] + w_{off}[n] \quad (5.12)$$

$$u_{out}[n] = w_g[n] u_0[n] \quad (5.13)$$

Die so ermittelten Filterkoeffizienten w_{off} und w_g werden anschließend in der Analyse zur Ermittlung der aktuellen Performancewerte der Schaltungskomponente herangezogen.

5.3.2. Referenzsignal

Für die Korrektur mittels der adaptiven Filter wird ein Referenzsignal d benötigt. Dieses stellt das erwartete Ausgangssignal der fehlerfreien Schaltung dar. Dieses Referenzsignal kann bspw. vor dem Betrieb der Schaltung aus Schaltungssimulationen extrahiert und abgespeichert werden, wie in [Hei19] vorgeschlagen. Dies bedeutet jedoch, dass das Referenzsignal lediglich für nominelle Betriebsbedingungen oder eine sehr begrenzte Anzahl an Szenarien vorliegt. Für den hier erarbeiteten Monitoring-Ansatz ist es jedoch erforderlich, dass das Referenzi-

gnal das Ausgangsverhalten zu den aktuell vorliegenden Operationsbedingungen bezüglich Umgebungstemperatur T und Versorgungsspannung V repräsentiert.

Zu diesem Zweck wird das Referenzsignal hier durch ein RSM-basiertes Verhaltensmodell bereitgestellt. Dabei handelt es sich um nicht-stochastische RSM-Verhaltensmodelle, welche als Grundlage der zuvor entwickelten stochastischen Modellierung in Kapitel 3 erläutert wurden. In dem Verhaltensmodell sind die vom Filter zu überwachenden Schaltungseigenschaften durch RSM-basierte Performancemodelle in Abhängigkeit von den Umgebungsparametern Temperatur T und Versorgungsspannung V modelliert. Die Veränderung der Performance über das Alter sowie Prozessvariationen werden nicht berücksichtigt. Das Verhaltensmodell an sich ist dabei möglichst einfach gehalten, da es mit Ausnahme der durch die RSM-Performancemodelle modellierten Abhängigkeiten das ideale Verhalten der Schaltung darstellt.

In der Abbildung 5.3 bezeichnen \mathcal{P}_{ref} die durch die RSMs berechneten Referenz-Performances, welche im Verhaltensmodell zur Bestimmung des Referenzsignals verwendet werden. Die Umgebungsparameter werden von On- oder Off-Chip Sensoren erfasst. Damit bildet das Verhaltensmodell das ideale Verhalten der Schaltung zum Zeitpunkt $t_{age} = 0$ für gegebene Umgebungsparameter ab. Die Referenz-Performances \mathcal{P}_{ref} werden im Weiteren in Kombination mit den resultierenden Filterkoeffizienten zur Ermittlung der aktuellen Schaltungsperformance herangezogen.

Mithilfe des digitalisierten Eingangs-Test-Signals wird durch das Verhaltensmodell das Referenzsignal d bestimmt.

5.3.3. Bestimmung der aktuellen Schaltungsperformance

Zur Ermittlung der aktuellen Performance \mathcal{P}_{est} werden die Filterkoeffizienten der adaptiven Filter und die durch die RSMs berechneten Referenzperformances \mathcal{P}_{ref} herangezogen. Die Filter haben die Ordnung $N = 0$, d.h. es gibt pro Filter einen Filterkoeffizienten: w_{off} für die Offset-Korrektur und w_g für den Verstärkungsfehler. Dadurch entsprechen die Filterkoeffizienten direkt dem aktuell vorliegenden Offset- und Verstärkungsfehler und die geschätzten Performances des CUT können folgendermaßen berechnet werden:

$$DC_{offset,t} = DC_{offset,ref} - w_{off} \quad (5.14)$$

$$gain_t = \frac{gain_{ref}}{w_g} \quad (5.15)$$

wobei \square_{ref} die jeweils durch die RSMs berechneten Referenzperformances innerhalb des Verhaltensmodells sind.

Durch periodisch auftretende Abweichungen zwischen dem Verhaltensmodell und dem CUT, welche durch die Idealisierungen im Modell oder periodische Messfehler hervorgerufen werden können, kann es bei den Filterkoeffizienten zu Oszillationen kommen. Aus diesem Grund ist es sinnvoll, für die Schätzung der Schaltungsperformance einen gleitenden Mittelwert über die zuletzt ermittelten Monitoring-Ergebnisse zu verwenden.

$$DC_{offset,est} = \overline{(DC_{offset,ref} - w_{off})} \quad (5.16)$$

$$(5.17)$$

$$gain_{est} = \left(\frac{gain_{ref}}{w_g} \right) \quad (5.18)$$

Idealerweise sind das Test- und Referenzsignal zum Zeitpunkt $t_{age} = 0$ identisch. Aufgrund von Modellfehlern der RSMs und der Idealisierungen des Verhaltensmodells ist jedoch ein Modellfehler zu erwarten. Darüber hinaus führen Prozessvariationen zu Abweichungen von der idealen im Verhaltensmodell modellierten Performance. Dies führt dazu, dass zur Zeit $t_{age} = 0$ ein initialer Fehler auftritt, welcher in initialen Filterkoeffizienten resultiert. Diese werden verwendet, um die reale initiale Schaltungsperformances zu ermitteln. Durch eine initiale Kalibrierung ist es somit möglich, die individuelle Prozessecke der Schaltung zu ermitteln, sodass die Notwendigkeit eines dedizierten Sensors zur Ermittlung der Prozessecke entfällt. Verändern sich nun die Schaltungsperformance durch Alterung über die Zeit, so führt dies auch zu einer Veränderung der Filterkoeffizienten. Auch sich verändernde Umgebungsparameter (Temperatur und Spannung) rufen eine Veränderung der Schaltungsperformance hervor. Um zwischen diesen beiden Ursachen unterscheiden zu können, sind in den RSMs die Abhängigkeiten von den Umgebungsparametern modelliert. Eine zusätzliche Veränderung der Filterkoeffizienten über die Zeit über den initialen Modellfehler hinaus kann somit der Alterung zugeschrieben werden. Dies zeigt auch, warum die Abhängigkeit von den Betriebsbedingungen in das Verhaltensmodell einbezogen werden muss: um verschiedene Ursachen für die Verschiebung der Filterkoeffizienten zu unterscheiden, muss ein Bezugspunkt bekannt sein. Würden nur die nominalen Performances einbezogen, wäre es nicht möglich, zu differenzieren, ob eine Verschiebung der Filterkoeffizienten, und damit der Performance auf Alterung oder eine Änderung der Betriebsbedingungen zurückzuführen ist. Zu diesem Zweck ist es auch erforderlich, den initialen Fehler zu Beginn in verschiedenen Betriebsbedingungen zu ermitteln.

5.3.4. Genauigkeit des Monitoring

Unter der Voraussetzung, dass die adaptiven Filter stabil sind und es nicht aufgrund zusätzlicher Einflüsse zu einer Verfälschung des Ausgangssignals der Schaltung kommt, entsprechen die durch das Monitoring-Verfahren ermittelten Performances dem aktuellen Zustand der Schaltung. Eine Abweichung kann, wie zuvor beschrieben, aufgrund der Idealisierungen des Verhaltensmodells auftreten, was durch die Bildung des gleitenden Mittelwerts berücksichtigt wird und zu einem geringen Fehler für \mathcal{P}_{est} führen kann.

Sensoren

Für das vorgestellte Monitoring-Konzept ist die Erfassung der aktuellen Umgebungsparameter Temperatur und Spannung der Schaltung notwendig. Die Messung der aktuellen Temperatur und Versorgungsspannung kann beispielsweise durch ein Ringsoszillator-basiertes Multisensorin-

terface, wie in [Ros21] gezeigt, erfolgen. Auf die Implementierung eines dedizierten Sensors zur Erfassung der vorliegenden Prozessvariation kann hier verzichtet werden, da die Prozessecke durch die initialen Filterkoeffizienten bestimmt werden kann.

Eine der grundlegenden Anforderungen, damit das Monitoring-Verfahren wie beschrieben funktioniert, ist, dass die Sensormessung unabhängig und robust gegenüber den Alterungseinflüssen ist, die das Verhalten der Schaltung verändern. Dies kann zum einen durch ein robustes Design erreicht werden. Eine andere Möglichkeit ist die nachträgliche rechnerische Korrektur der Messung anhand bekannter Abhängigkeiten. Die Abhängigkeit der Sensoren von den im Verhaltensmodell berücksichtigten Einflussparametern ist dagegen unerheblich, solange diese nicht über die Zeit veränderlich sind und durch einen funktionalen Zusammenhang über den Definitionsbereich beschrieben werden können. In diesem Fall resultieren die Ungenauigkeiten der Messung bei der initialen Kalibration in einem zusätzlichen Fehler, der in den initialen Filterkoeffizienten resultiert.

5.4. Zusammenfassung

In diesem Kapitel wurde das hier entwickelte Monitoring-Verfahren zur Überwachung der aktuellen Schaltungsperformance sowie zur Detektion von Alterung vorgestellt. Es basiert auf einem bestehenden Ansatz zur Online-Korrektur von Fehlern innerhalb analoger Sensor-Interfaceschaltungen mittels digitaler adaptiver Filter. Dies wird hier um die Verwendung RSM-basierter Verhaltensmodelle erweitert. Die RSMs berechnen die idealen fehlerfreien Referenzperformances (DC-Offset und Verstärkung) der Schaltung zu den aktuellen, von Sensoren gemessenen Betriebsbedingungen bzgl. Temperatur und Spannung. Dies wird zur Bestimmung des idealen zu erwartenden Referenzsignals, welches für die Korrektur mit den adaptiven Filtern benötigt wird, genutzt. Die resultierenden Filterkoeffizienten und die Referenzperformances ermöglichen anschließend die Berechnung der aktuellen tatsächlichen Schaltungsperformance. Die Überwachung der Filterkoeffizienten, bzw. der daraus ermittelten Monitoring-Ergebnisse für die Schaltungsperformance über die Zeit, ermöglicht zudem die Detektion von Alterung.

**6**

Monitoring-Ergebnisse

In diesem Kapitel wird die Eignung des entwickelten Monitoring-Verfahrens untersucht, um die aktuelle Schaltungsperformance zu überwachen und darüber hinaus Degradierung zu detektieren. Dabei erfolgt zunächst eine simulationsbasierte Untersuchung anhand von Beispielschaltungen in einem 28nm FDSOI Prozess. Dieser ermöglicht auch die kombinierte Simulation von Alterung und Prozessvariation, sodass sowohl die initiale Variation als auch Degradierung analysiert werden können.

Für die Analyse des vorgestellten Monitoring-Konzepts wurden die Filter und Algorithmen aus Abbildung 5.3 in MATLAB Simulink implementiert.

Bei der anschließenden messtechnischen Verifikation wird das Verfahren anhand einer handelsüblichen Operationsverstärkerschaltung getestet. Dabei erfolgt die Überwachung der durch die Veränderung der äußeren Betriebsbedingungen Temperatur und Versorgungsspannung hervorgerufenen Performanceänderung.

6.1. Simulative Evaluation des Monitoring-Verfahrens

Zunächst werden die verwendeten Beispielschaltungen sowie deren Parameter und die für das Monitoring benötigten RSMs beschrieben. Anschließend erfolgt die Analyse der Ergebnisse des Monitoring für verschiedene Szenarien, mit und ohne Berücksichtigung von Prozessvariation oder Alterung.

Die RSMs für den linearen Verstärkungsfaktor und den DC-Offset werden in Abhängigkeit von der Temperatur T und der Versorgungsspannung V_{dd} auf der Grundlage von Simulationen der Schaltungen im Spectre-Simulator von Cadence Virtuoso erstellt. Das Verhaltensmodell beschreibt einen idealen Verstärker mit linearer Verstärkung und DC-Offset, der durch die RSMs modelliert wird. Frequenzgang und Anstiegsgeschwindigkeiten oder Verzögerungen werden nicht modelliert.

Da das Monitoring in der digitalen Domäne stattfindet, werden die aus der Simulation gewonnenen analogen Ausgangssignale durch einen ebenfalls in Simulink implementierten ADC mit einer Auflösung von 16 Bit digitalisiert.




Abbildung 6.1.: Aufbau des differentiellen Cascode-Operationsverstärkers.

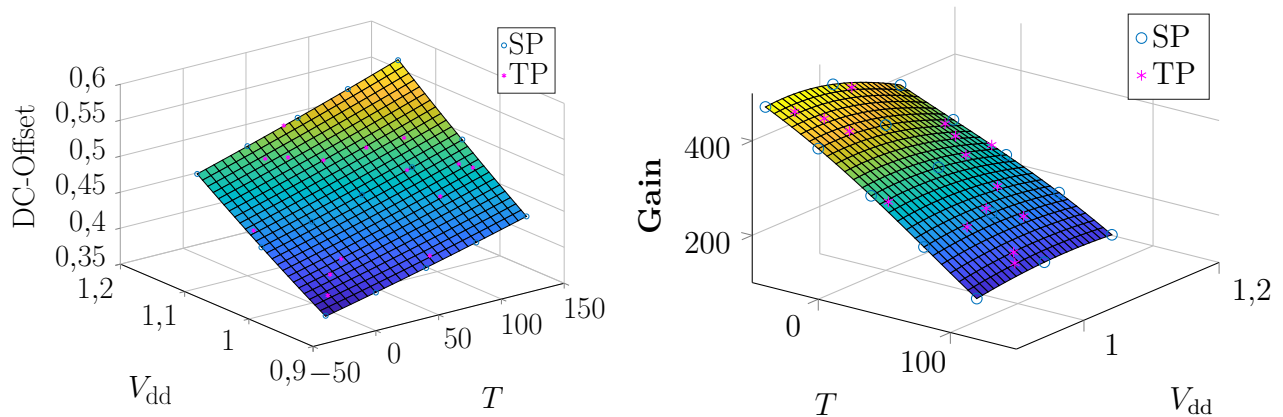


Abbildung 6.2.: RSMs des linearen Verstärkungsfaktors und des DC-Offset über Temperatur und Spannung für den differentiellen Cascode-Operationsverstärker.


6.1.1. Beispielschaltungen

In diesem Abschnitt werden die für die Analyse der entwickelten Monitoring-Methode verwendeten Beispielschaltungen vorgestellt. Dabei handelt es sich um zwei verschiedene Verstärkertopologien aus [Bak10], welche im 28-nm-FDSOI-Prozess von STMicroelectronics implementiert wurden. Das PDK umfasst vom Hersteller bereitgestellte HCI- und NBTI-Alterungsmodelle für den nativen Cadence-Spectre-Alterungssimulator. Das Verhalten der Verstärkers wird für Temperaturen zwischen -40 °C und 120 °C und die Versorgungsspannung V_{dd} zwischen $0,9\text{ V}$ und $1,1\text{ V}$ mit einer Nennspannung von $V_{dd} = 1\text{ V}$ über einen Bereich von $t_{age} = 10$ Jahren (315360000 sec) analysiert. Bei der Auswahl der Beispielschaltungen stand die Abhängigkeit ihrer Performances von den Betriebsbedingungen im Vordergrund, um das entwickelte Monitoring-Verfahren testen zu können. Sie wurden nicht anhand der Möglichkeit einer praktischen Implementierung ausgewählt.

Im Folgenden werden die Schaltungen mit ihren wichtigsten Performanceparametern sowie den für das Monitoring verwendeten RSMs gezeigt. Für jede Verstärkertopologie wird jeweils ein RSM für die lineare Verstärkung sowie für die DC-Offset-Spannung erstellt.

Tabelle 6.1.: Modellfehler der RSMs für Cascode-Operationsverstärker.

	Modelltyp	MAPE	MAE
Verstärkung (Gain)	Gauss-RBF ($c=0,3$)	0,021	15,2082
DC-Offset	Quadratic	0,0059	0,0069

**Abbildung 6.3.:** Alterung der Verstärkung und des DC-Offset bei verschiedenen Betriebsbedingungen über einen Zeitraum von 10 Jahren.

6.1.1.1. Differentieller Cascode-Operationsverstärker

Die erste Testschaltung stellt einen differentiellen Cascode-Operationsverstärker in Open-Loop Konfiguration dar, dessen Aufbau in Abbildung 6.1 gezeigt ist. Die Dimensionierung der einzelnen Transistoren ist im Anhang A.2 gegeben.

Bei nominellen Betriebsbedingungen ($T = 27 \text{ °C}$, $V_{\text{dd}} = 1 \text{ V}$) beträgt der lineare Verstärkungsfaktor $\text{Gain} = 366,3$ (51,28 dB) und der DC-Offset liegt bei 476,6 mV. Die RSMs des DC-Offset sowie der Verstärkung sind in der Abbildung 6.2 dargestellt, inklusive der zur Berechnung der RSMs verwendeten Stützpunkte (SP). Diese zeigen den Verlauf dieser Performances in Abhängigkeit von der Temperatur und der Versorgungsspannung, welche eine starke Veränderung hervorrufen. Für die Modellierung wurden die in Abschnitt 3.3 vorgestellten RSM-Funktionen verwendet. Die Genauigkeit der RSMs wird in 15 Testpunkten (TP) evaluiert, welche durch das Latin-Hypercube Samplingverfahren erstellt wurden. Diese Testpunkte sind ebenfalls in den Grafiken abgebildet. Die ermittelten Modelle und Modellfehler sind in der Tabelle 6.1 gezeigt. Darüber hinaus ist in Abbildung 6.3 das Alterungsverhalten in den Eckpunkten des Definitionsbereichs der Betriebsbedingungen gezeigt. Dabei ist ersichtlich, wie stark die Degradierung von den jeweiligen Betriebsbedingungen abhängig ist. Dies zeigt sich insbesondere im Fall der Verstärkung, wobei das Alterungsverhalten in einem Eckpunkt ($T = 120 \text{ °C}$, $V_{\text{dd}} = 1,1 \text{ V}$) sogar invertiert ist.

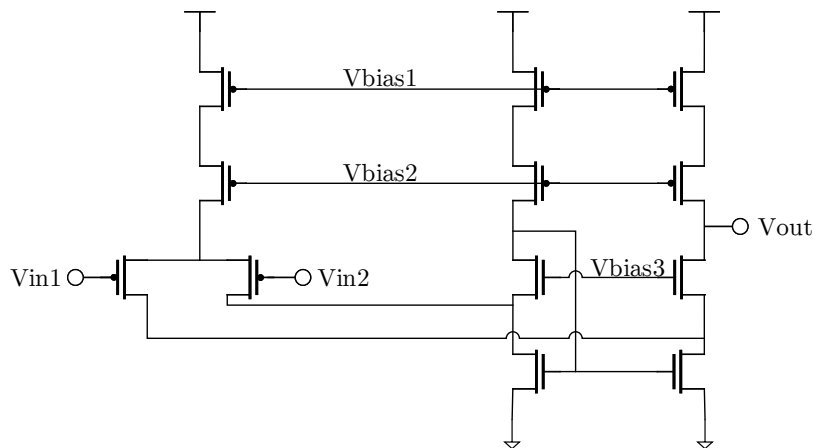


Abbildung 6.4.: Aufbau des Folded-Cascode Verstärkers

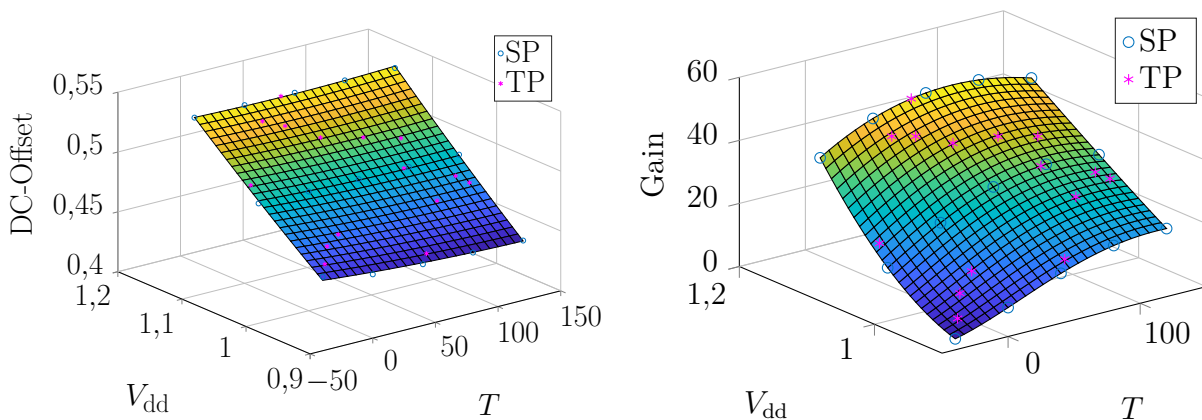



Abbildung 6.5.: RSMs des linearen Verstärkungsfaktors und des DC-Offset über Temperatur und Spannung für den Folded-Cascode-Operationsverstärker.

6.1.1.2. Folded-Cascode-Operationsverstärker

Als zweite Beispielschaltung dient ein Folded-Cascode-Operationsverstärker, dessen Topologie in Abbildung 6.4 gezeigt ist. Die Dimensionierung ist im Anhang A.3 gegeben. In der reinen Open-Loop-Konfiguration ist die Schaltung aufgrund des extrem starken Einflusses der Prozessvariation unbrauchbar. Daher wird dieser Verstärker für die Simulation mit einem Rückkopplungsnetzwerk versehen, um den Arbeitspunkt zu stabilisieren. Dies sorgt erwartungsgemäß ebenfalls für einen geringeren Einfluss von Alterung, wie die nachfolgende Analyse zeigt. Bei nominellen Betriebsbedingungen ($T = 27 \text{ °C}$, $V_{\text{dd}} = 1 \text{ V}$) beträgt die Verstärkung 27,38 (28,75 dB) und der DC-Offset liegt bei 499,6 mV. Die RSMs des DC-Offset sowie der Verstärkung sind in der Abbildung 6.5 dargestellt, inklusive der zur Berechnung der RSMs verwendeten Stützpunkte (SP). Diese zeigen den Verlauf dieser Performances in Abhängigkeit von der Temperatur und der Versorgungsspannung. Im Vergleich zu der bereits betrachteten Beispielschaltung ist die Abhängigkeit des DC-Offset von der Temperatur aufgrund der Rückkopplung geringer. Die Genauigkeit der RSMs wird in 15 zusätzlichen Testpunkten (TP) evaluiert, welche durch das

Tabelle 6.2.: Modellfehler der RSMs für Folded-Cascade-Operationsverstärker.

	Modelltyp	MAPE	MAE
Verstärkung (Gain)	Gauss-RBF ($c=0,1$)	0,0522	2,135
DC-Offset	Quadratic	0,0051	0,0044

**Abbildung 6.6.:** Alterung der Verstärkung und des DC-Offset des Folded-Cascade-Verstärkers bei verschiedenen Betriebsbedingungen über einen Zeitraum von 10 Jahren.

Latin-Hypercube-Samplingverfahren erstellt wurden. Diese Testpunkte sind ebenfalls in den Grafiken abgebildet. Die ermittelten Modelle und Modellfehler sind in der Tabelle 6.2 gezeigt. In Abbildung 6.6 ist das Alterungsverhalten der Performances des Folded-Cascade-Verstärkers gezeigt. Aufgrund der verwendeten Rückkopplung fällt diese deutlich geringer aus als bei der zuvor betrachteten Verstärkerschaltung in Open-Loop-Konfiguration.

6.1.2. Zustandsüberwachung ohne Prozessvariation

Zunächst wird das Monitoring-Verfahren ohne die Berücksichtigung von Prozessvariation betrachtet. Zu diesem Zweck wird der zuvor beschriebene differentielle Cascade-Operationsverstärker unter verschiedenen Betriebsbedingungen und Alterung simuliert und die resultierenden Signale für das Monitoring herangezogen. Als Testsignal dient ein Sinussignal mit 500 Hz Frequenz und einer, aufgrund der hohen Leerlaufverstärkung, Amplitude von 0,1 mV. Das Testintervall beträgt 100 ms, wobei das Ausgangssignal mit einer Frequenz von 50 kHz abgetastet wird.

In Abbildung 6.7 sind die transienten Test- und Referenzsignale für zwei Fälle dargestellt. Im ersten Fall mit den Parametern $T = 30\text{ °C}$ und $V_{\text{dd}} = 1\text{ V}$ zum Zeitpunkt $t_{\text{age}} = 0$ stimmen das Testsignal und das durch das Verhaltensmodell generierte Referenzsignal gut überein. Im zweiten Fall werden die Signale für eine andere Parameterkombination ($T = -10\text{ °C}$ und

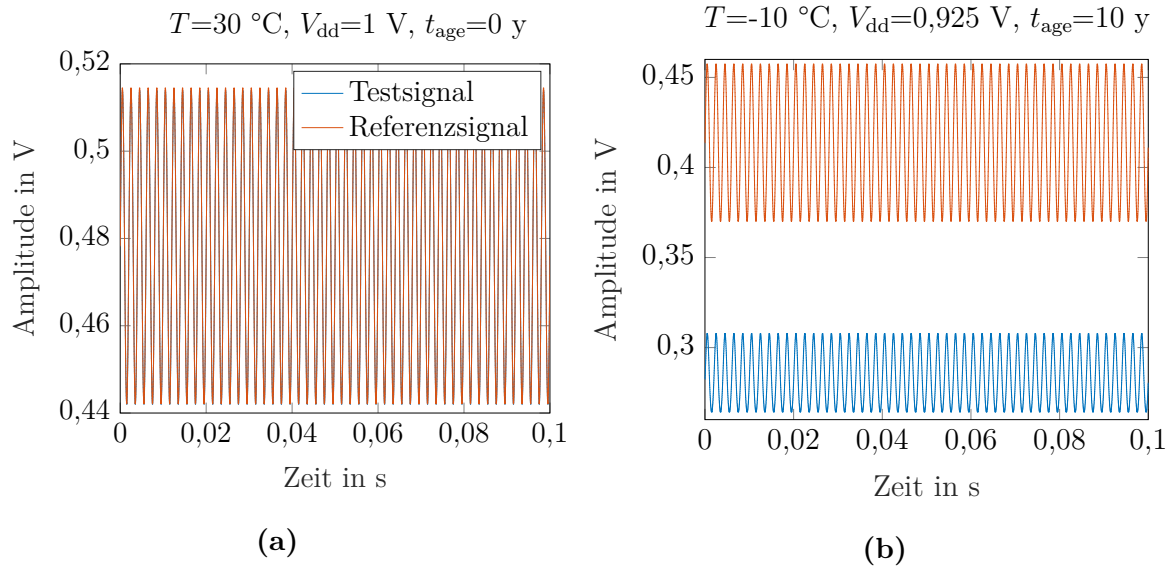


Abbildung 6.7.: Test- und Referenzsignal des a) ungealterten und b) gealterten differentiellen Cascode-Operationsverstärkers.

$V_{dd} = 0,925\text{ V}$, $t_{age} = 10\text{ y}$) gezeigt. Dabei zeigt sich eine sehr starke Abweichung des Testsignals aufgrund von Alterung; das Referenzsignal repräsentiert das ideale zu erwartende Signal ohne Alterung wie es vom Verhaltensmodell bestimmt wird.

Als Schrittweiten werden hier $\mu_{off} = 0,08$ gewählt, während die Schrittweite im Fall ohne Alterung $\mu_g = 5$ und mit Alterung $\mu_g = 7$ beträgt, um eine schnellere Konvergenz bei größerer Abweichung zu erreichen.

In Abbildung 6.8 sind die Fehlersignale und Filterkoeffizienten sowie die resultierenden Monitoring-Ergebnisse der Performances für den zuvor beschriebenen ersten Fall gezeigt. Die Abweichung zwischen Test- und Referenzsignal bzgl. des Offset-Fehlers ist äußerst gering. Bei der Betrachtung des Verstärkungsfehlers und des resultierenden Filterkoeffizienten wird das Problem der bereits erwähnten Oszillation aufgrund periodischer Abweichungen zwischen Test- und Referenzsignal deutlich. Aufgrund dessen wird für die Ermittlung der Schaltungsperformance ein gleitender Mittelwert herangezogen. Die periodische Abweichung wird in diesem Fall durch einen leichten zeitlichen Versatz zwischen dem Referenzsignal und dem Testsignal hervorgerufen, welcher auf der Tatsache beruht, dass im Verhaltensmodell keine Verzögerungen (Delays) berücksichtigt werden.

Der Vergleich zu dem Fall, in dem eine starke Abweichung zwischen Referenz- und Testsignal auftritt, ist in Abbildung 6.9 dargestellt. Hier zeigt sich, dass der anfänglich große Fehler zwischen Referenz- und Testsignal gut durch das adaptive Filter korrigiert wird, sodass ein im Vergleich dazu nur geringer Restfehler verbleibt.




Abbildung 6.8.: Fehlersignale, Filterkoeffizienten und resultierende Monitoring-Ergebnisse der Performances im Fall geringer Abweichung der ungealterten Schaltung ($T = 30 \text{ }^\circ\text{C}$, $V_{dd} = 1 \text{ V}$, $t_{age} = 0 \text{ y}$).

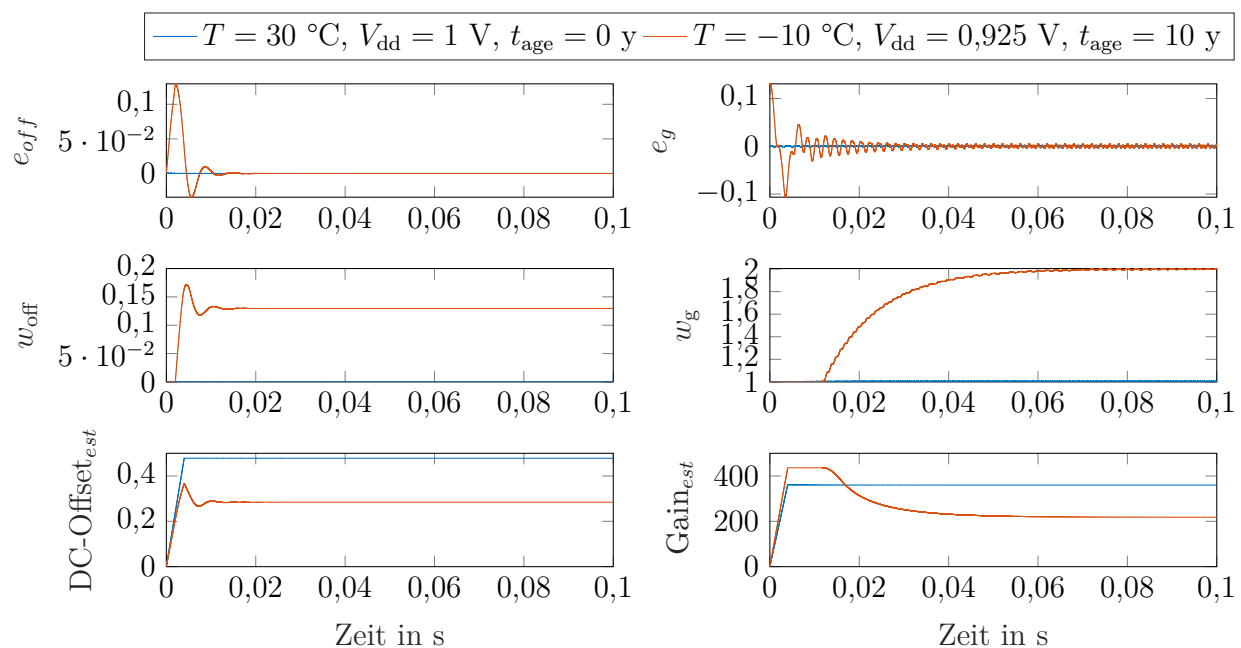


Abbildung 6.9.: Fehlersignale, Filterkoeffizienten und resultierende Monitoring-Ergebnisse der Performances im Vergleich für geringe und starke Abweichung vom idealen Referenzsignal (ungealterte und gealterte Schaltung).

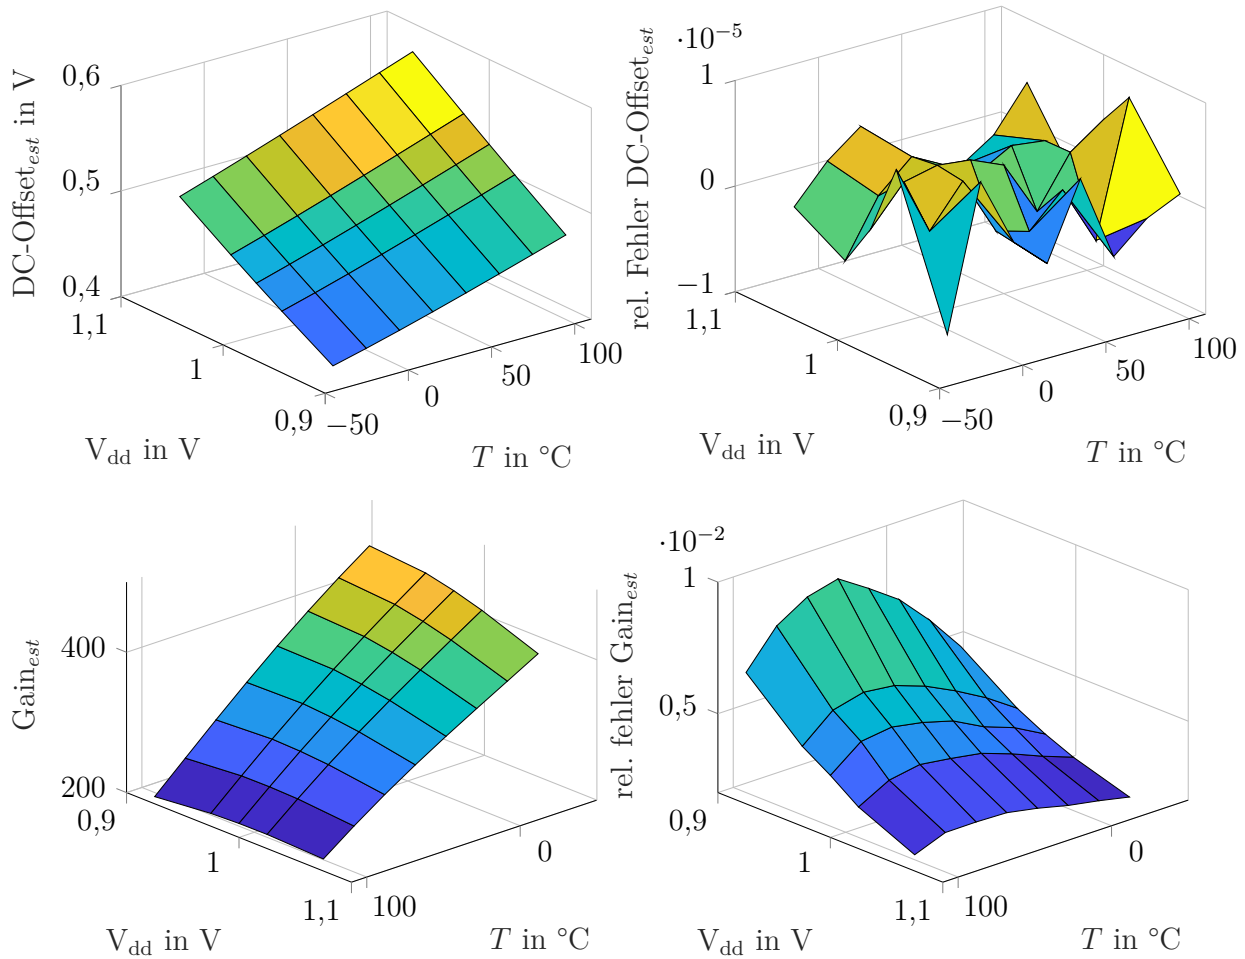


Abbildung 6.10.: Monitoring-Ergebnisse für Verstärkung und DC-Offset sowie relativer Fehler im Vergleich zu spectre Simulationen bei $age = 0$.

Genauigkeit des Monitoring

Die Genauigkeit der Monitoring-Ergebnisse wird zunächst zum Zeitpunkt $t_{age} = 0$ und bei verschiedenen Bedingungen für T und V_{dd} analysiert, welche sich von den Abtastpunkten unterscheiden, die zur Erstellung der RSMs für das Verhaltensmodell verwendet wurden. Der Schätzfehler wird durch den Vergleich von P_{est} mit den Performancewerten aus Spectre-Schaltungssimulationen berechnet. Als Monitoring-Ergebnis wird jeweils der am Ende des Monitoring-Intervalls durch den gleitenden Mittelwert bestimmte Wert für DC-Offset_{est} sowie Gain_{est} herangezogen.

Die Ergebnisse sind in Abb. 6.10 dargestellt. Es ist zu erkennen, dass der anfängliche Modellfehler nur einen kleinen Fehler in der Performanceschätzung bei $t_{age} = 0$ verursacht. Der Schätzfehler für den DC-Offset ist vernachlässigbar gering. Bei der Verstärkung ist ein etwas größerer Restfehler zu beobachten, der durch die periodische Oszillation und die anschließende Verwendung des Mittelwertes für die Schätzung verursacht wird.

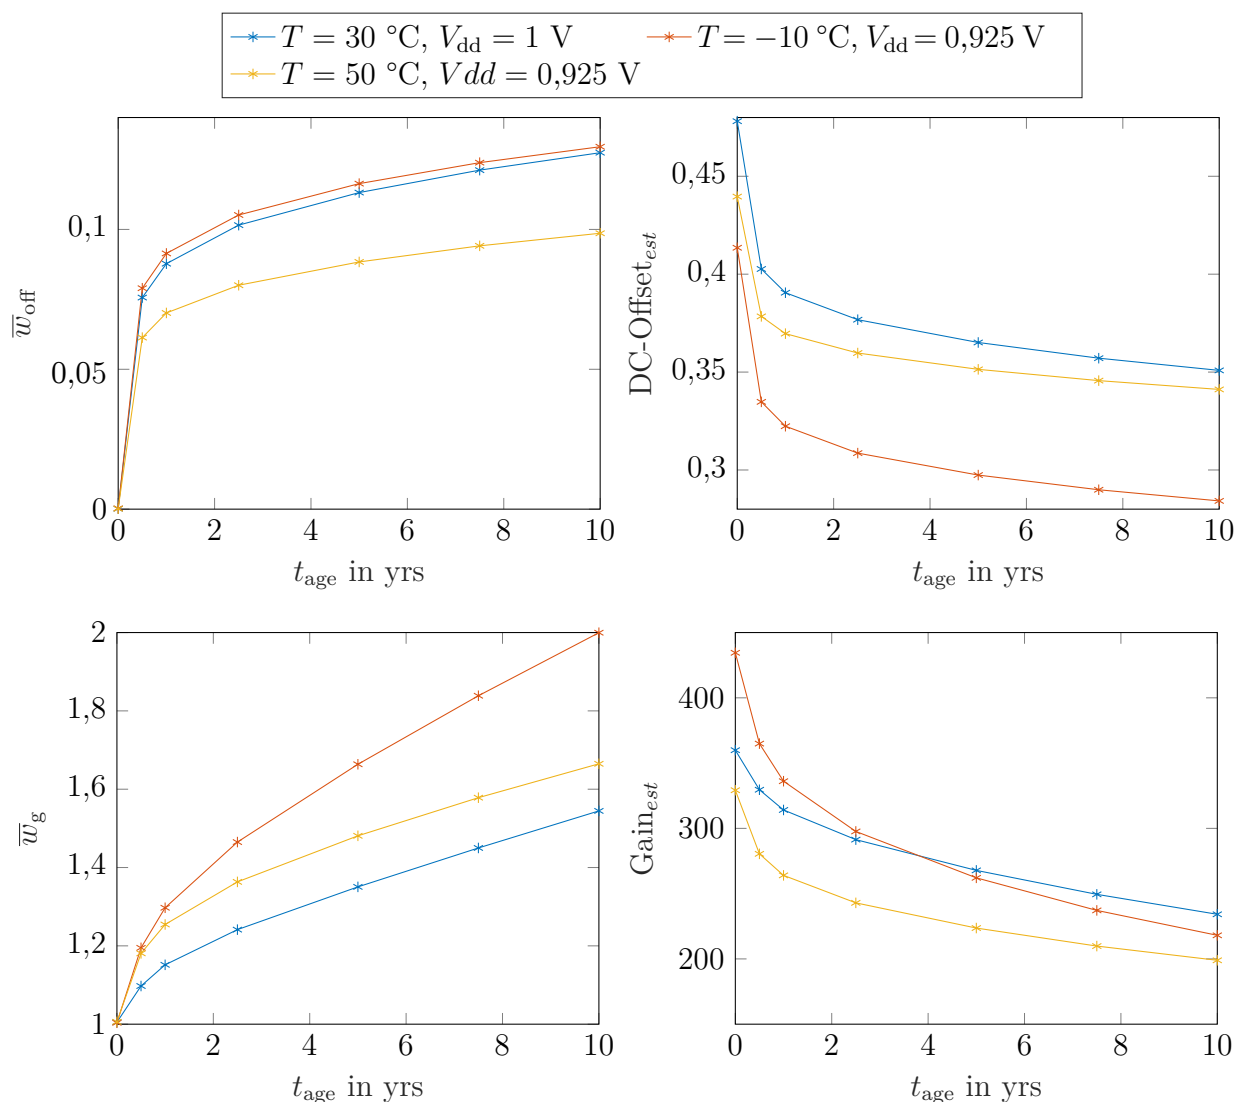


Abbildung 6.11.: Veränderung der Filterkoeffizienten w_{off} und w_g über das Alter und resultierende Monitoring-Ergebnisse für verschiedene Bedingungen.

6.1.2.1. Degradationsmonitoring

Um die Veränderung der Performances durch Alterung zu überwachen, wird die Verschiebung der Filterkoeffizienten und die daraus bestimmten Performances im Laufe der Zeit beobachtet, wie in Abb. 6.11 dargestellt. Die hier dargestellten Werte entsprechen dem gleitenden Mittelwert am Ende des Monitoring-Intervalls. Dabei wird deutlich, wie unterschiedlich die Alterung bei verschiedenen Bedingungen ausfällt.

Die Verschiebung der Filterkoeffizienten \bar{w}_{off} und \bar{w}_g sowie die daraus resultierenden Monitoring-Ergebnisse für die Performancewerte über das Alter bei verschiedenen Temperaturen und V_{dd} ist in Abb. 6.12 dargestellt. Es ist zu erkennen, dass die Verschiebung aufgrund der Degradation in der Regel deutlich größer ist als der ursprüngliche Modellfehler. Dies ermöglicht die Analyse der Degradation. Es wird auch deutlich, dass der Einfluss der Alterung bei niedrigeren Temperaturen,

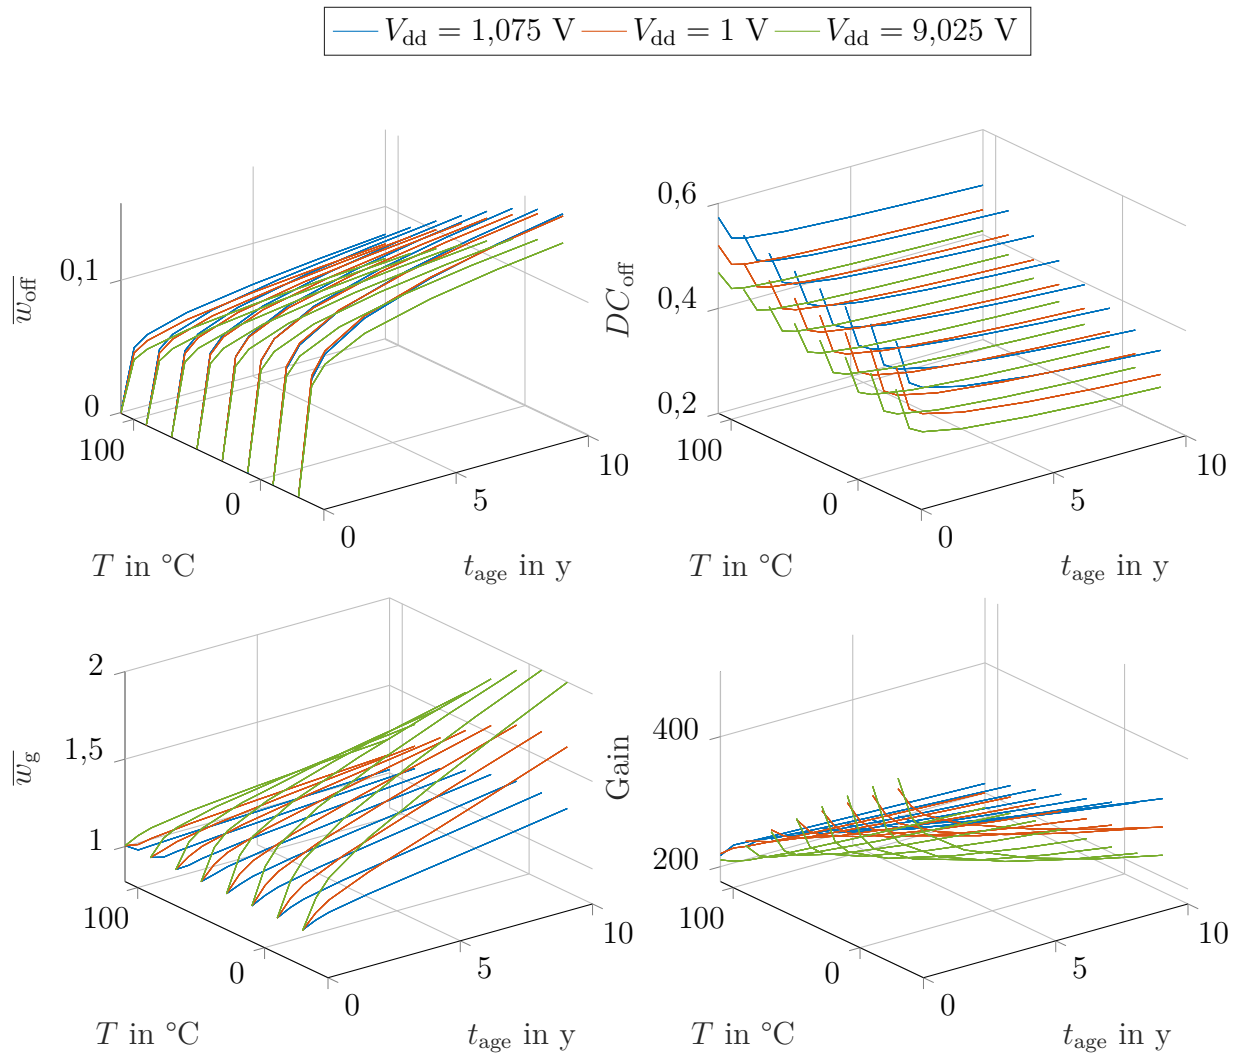


Abbildung 6.12.: Veränderung der Filterkoeffizienten $\overline{w_g}$ und $\overline{w_{off}}$ über das Alter bei verschiedenen Temperaturen und V_{dd} sowie die daraus ermittelten Performanzenwerte für Verstärkung und DC-Offset.

bei denen die ursprüngliche Verstärkung höher war, größer ist als bei hohen Temperaturen, bei denen die Verstärkung ursprünglich niedriger war.

Die sich daraus ergebenden Monitoring-Ergebnisse der gealterten Performance für die Verstärkung und den DC-Offset ist in Abb. 6.13 dargestellt. Auch hier ist der relative Fehler im Vergleich zu den simulierten Werten aus der Spectre-Simulation gering, was zeigt, dass eine gute Schätzung der Schaltungsperformance möglich ist.

Diese Untersuchung macht auch deutlich, warum die Abhängigkeit von den Betriebsbedingungen in das Verhaltensmodell einbezogen werden muss: Um zwischen verschiedenen Ursachen für die Verschiebung der Filterkoeffizienten unterscheiden zu können, muss ein Bezugspunkt bekannt sein. Würden nur die nominalen Performances einbezogen, könnte nicht festgestellt werden, ob eine Verschiebung der Performance und damit der Filterkoeffizienten durch Alterung oder durch eine Änderung der Betriebsbedingungen verursacht wird.

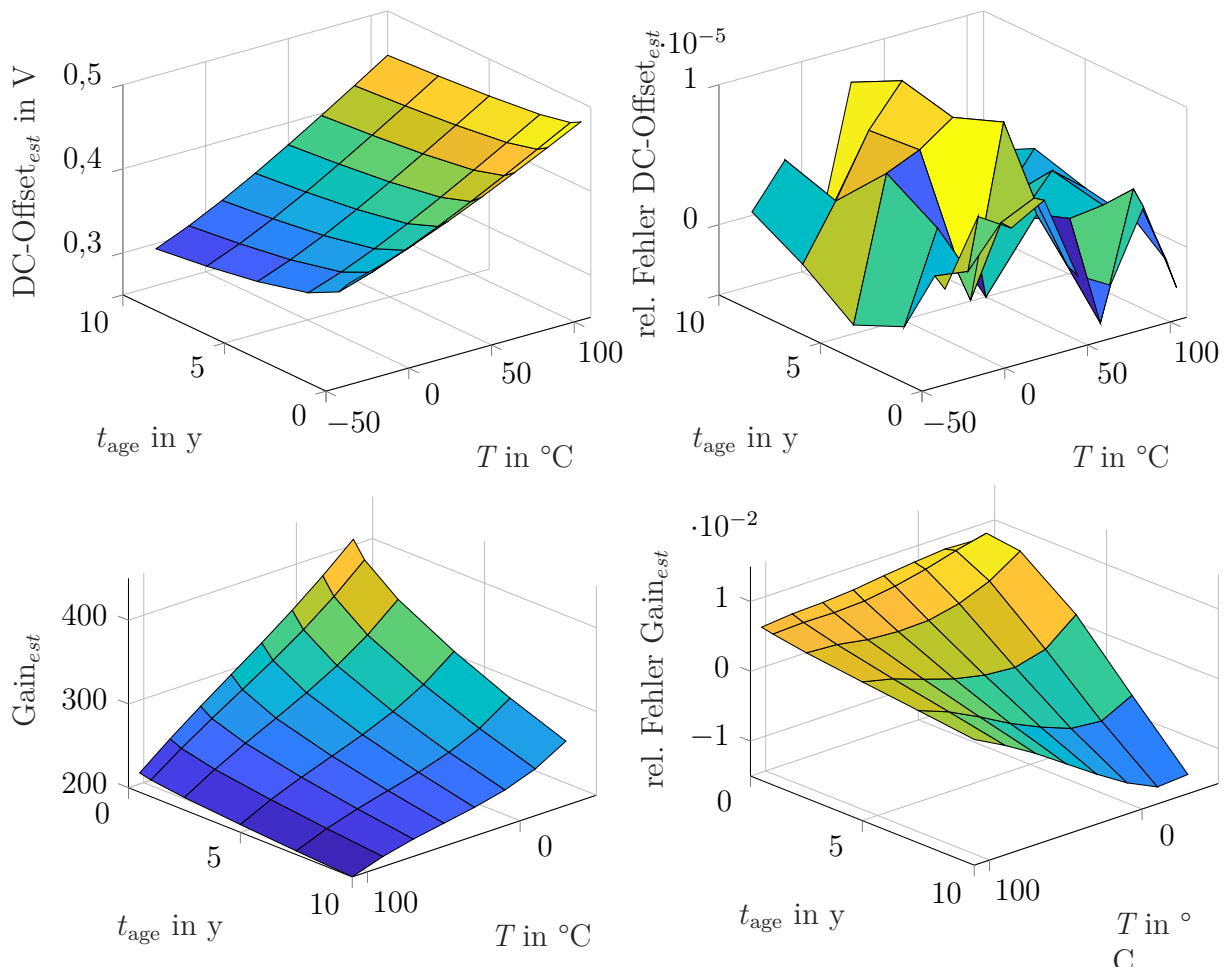


Abbildung 6.13.: Monitoring-Ergebnisse der gealterten Performance über das Alter und die Temperatur bei $V_{\text{dd}} = 1 \text{ V}$ sowie der relative Fehler im Vergleich zu den Spectre-Simulationen.

6.1.3. Monitoring mit Prozessvariation

Als Beispielschaltung wird hier der Folded-Cascade-Verstärker verwendet. Zusätzlich zu den Veränderungen durch die Betriebsbedingungen und Alterung wird nun der Einfluss von Prozessvariation untersucht. Wie bereits beschrieben, wird diese durch eine initiale Kalibrierung erfasst, was in initialen Filterkoeffizienten resultiert, durch welche sich die reale Schaltungsperformance ermitteln lässt. Als feste Schrittweiten für die Filter werden hier wie zuvor $\mu_{\text{off}} = 0,08$ sowie $\mu_g = 7$ gewählt. Zunächst wird hier das Monitoring-Verfahren bei Prozessvariation ohne die zusätzliche Berücksichtigung von Alterung analysiert. Im zweiten Schritt erfolgt dann die gleichzeitige Analyse von Prozessvariation und alterungsbedingter Degradierung.

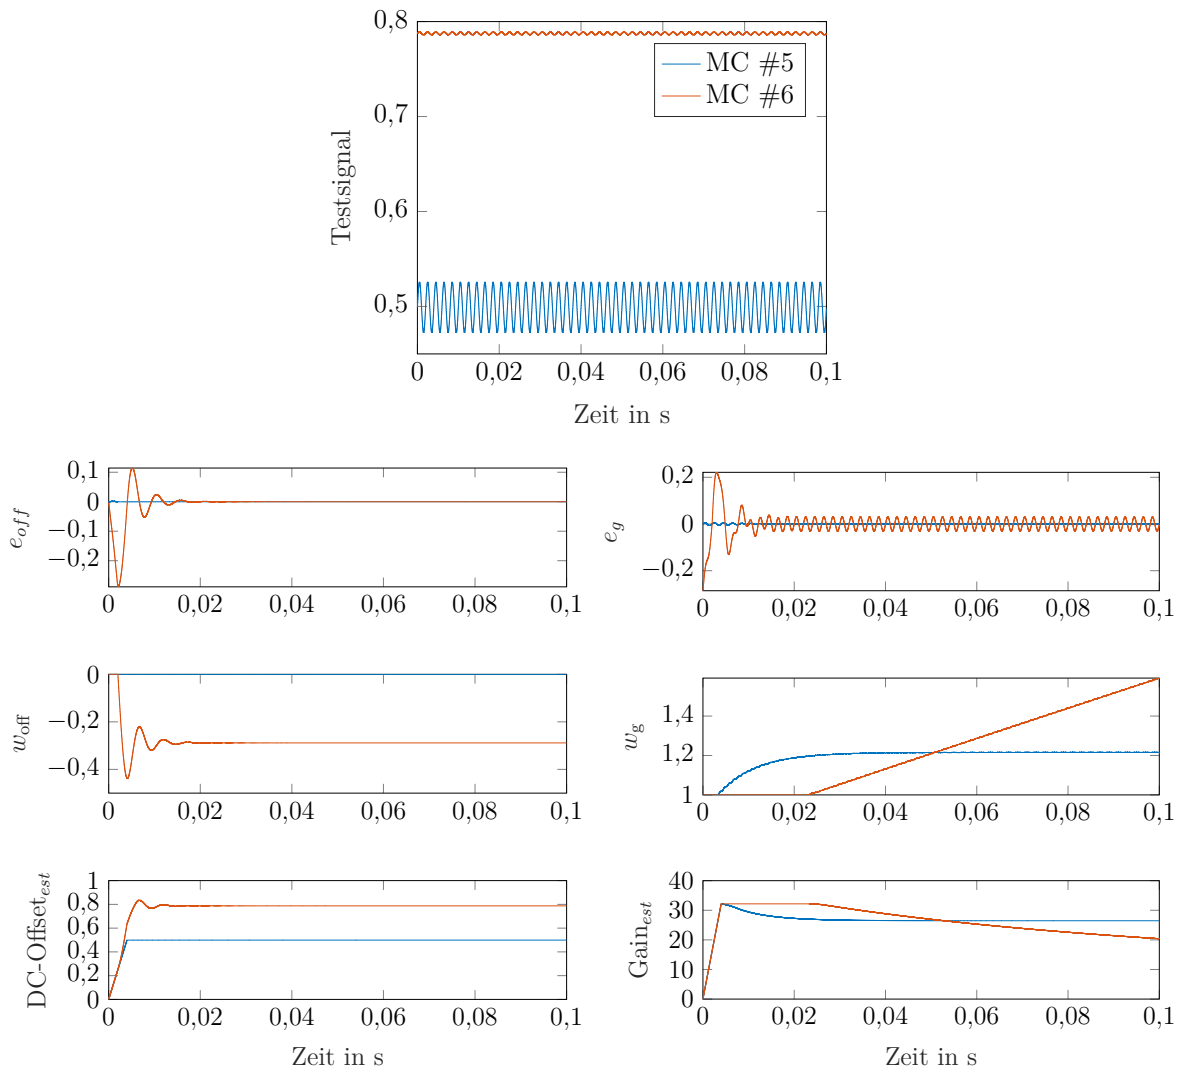
6.1.3.1. Prozessvariation ohne Alterung

Zunächst werden verschiedene Prozesspunkte unter nominalen Bedingungen ($T = 27 \text{ }^{\circ}\text{C}$, $V_{\text{dd}}=1 \text{ V}$) betrachtet. In den Fällen, in denen die Schaltung aufgrund von Prozessvariation nicht funktionstüchtig ist, kann es dazu kommen, dass die Filter keinen stabilen Zustand

Tabelle 6.3.: Spezifikationsgrenzen für den Folded-Cascode-Operationsverstärker.

	min	max
lin. Verstärkung	20	40
DC-Offset	0,4	0,6

erreichen. Dies, sowie der verbleibende große Restfehler wird genutzt, um diese Fälle zu identifizieren. Zur Überprüfung der Stabilität des Filterergebnisses werden die letzten 50 Werte der Monitoring-Ergebnisse herangezogen und deren Variation überprüft. Liegt diese unter einem Schwellwert, wird das Filterergebnis als stabil gewertet. Darüber hinaus können die Monitoring-Ergebnisse mit gegebenen Spezifikationsgrenzen abgeglichen werden, um fehlerhafte Schaltungen zu identifizieren. In diesem Beispiel wurden die Spezifikationsgrenzen wie in Tabelle 6.3 angegeben gesetzt.

**Abbildung 6.14.:** Vergleich von zwei MC-Punkten. MC-Punkt 5 liegt innerhalb der Spezifikationen, MC-Punkt 6 ist nicht funktionstüchtig.

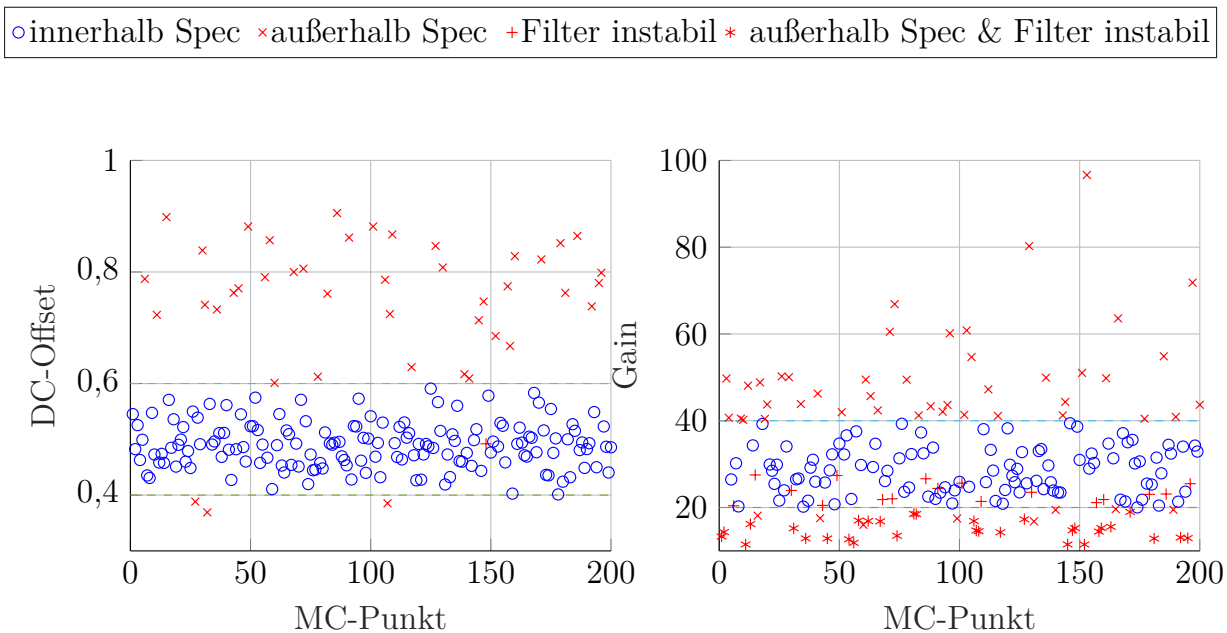


Abbildung 6.15.: MC-Punkte mit Kennzeichnung fehlerhafter Schaltungen (außerhalb der Spezifikation) sowie instabilem Filterergebnis.

In Abbildung 6.14 sind die Filtereingangssignale, Fehlersignale, Filterkoeffizienten und Monitoring-Ergebnisse für zwei MC-Punkte dargestellt. Für den MC-Punkt 5 liegen beide Performances innerhalb der Spezifikationen, beide Filter erreichen einen stabilen Zustand und ermöglichen somit die Ermittlung der Performancewerte. Im Fall des MC-Punkt 6 ist die Schaltung aufgrund der Prozessvariation nicht funktionsfähig. Der DC-Offset-Fehler kann mithilfe des Filters korrigiert werden, sodass hier der tatsächliche Wert als Monitoring-Ergebnis vorliegt. Bei der Verstärkung zeigt sich ein anderes Bild. Hier erreicht der Filter keine Konvergenz innerhalb des Testintervalls und das Monitoring-Ergebnis ist unbrauchbar. Dies ist hier auf die sehr langsame Anpassung des Filterkoeffizienten w_g aufgrund der kleinen Signalamplitude in Kombination mit der großen Abweichung vom Referenzsignal zurückzuführen. Wie bereits beschrieben werden diese Fälle, in denen kein stabiler Filterzustand erreicht wird, detektiert, um fehlerhafte Monitoring-Ergebnisse zu erkennen.

Das Ergebnis, bzw. die Auswertung der Monitoring-Ergebnisse für 200 MC-Punkte ist in Abbildung 6.15 gezeigt. Hier ist gekennzeichnet, ob die beim Monitoring ermittelte Performance innerhalb der Spezifikationsgrenzen liegt oder außerhalb. Zudem ist gezeigt, in welchen Fällen der jeweilige Filter am Ende des Monitoring-Intervalls von 100 ms keinen stabilen Zustand erreicht und das Ergebnis somit fehlerhaft ist. Da das Filterergebnis in den Fällen eines instabilen Filters innerhalb der Spezifikationen liegen kann, können diese Fälle durch die zusätzliche Information über die Filterstabilität identifiziert werden.

Der Vergleich der Monitoring-Ergebnisse mit den Simulationsergebnissen in Abbildung 6.16 zeigt, dass die instabilen Filterergebnisse in den Fällen nicht funktionsfähiger Schaltungen auftreten und diese somit richtig identifiziert werden.




Abbildung 6.16.: Absolute und relative Fehler der Monitoring-Ergebnisse für die einzelnen MC-Punkte.

Die nicht funktionsfähigen Schaltungen werden während der initialen Kalibration oder durch andere vorangegangene Testverfahren identifiziert. Ihre weitere Überwachung erübrigt sich daher.

6.1.3.2. Prozessvariation mit Alterung

Nachdem gezeigt wurde, dass das entwickelte Monitoring-Verfahren die Berücksichtigung von Prozessvariation erlaubt, wird nun die Überwachung in Kombination mit Alterung untersucht. Dabei wurden 10 MC-Punkte ausgewählt, welche innerhalb der Spezifikationen liegen, und ihr Verhalten über einen Zeitraum von 10 Jahren simuliert und überwacht.

Die Ergebnisse sind in Abbildung 6.17 dargestellt. Die Degradierung des DC-Offset ist sehr gering. Bei der Verstärkung kommt es zunächst zu einer starken Veränderung, die mit der Zeit abnimmt. Zum Vergleich der Monitoring-Ergebnisse sind zudem die direkt aus der Schaltungssimulation extrahierten Performancewerte dargestellt.

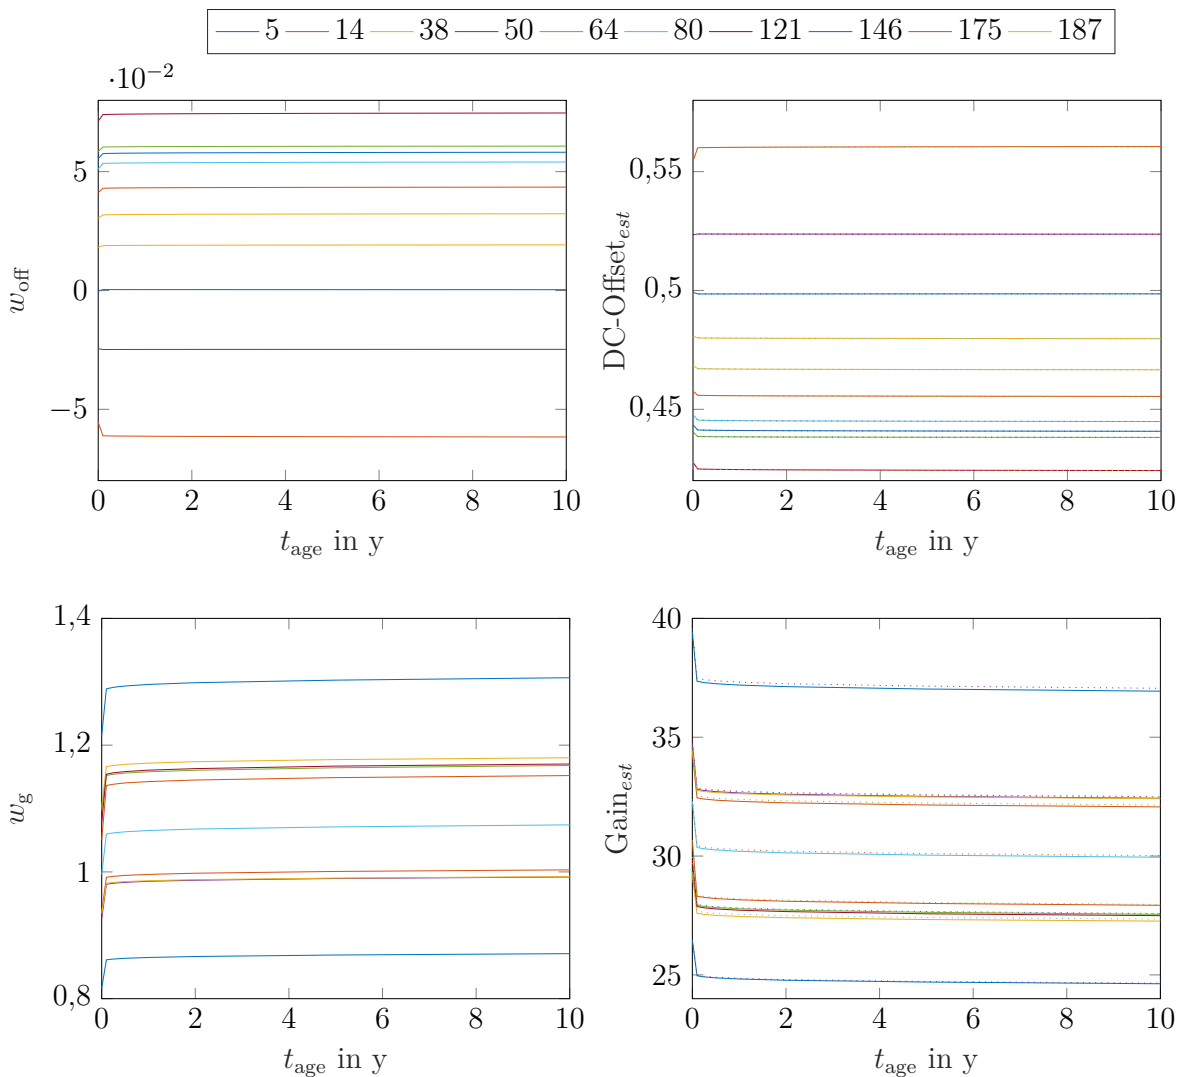


Abbildung 6.17.: Zeitlicher Verlauf der Filterkoeffizienten und der daraus ermittelten Performances für 10 verschiedene MC-Punkte. Die direkt aus der Simulation extrahierten Performances sind gestrichelt dargestellt.

In Abbildung 6.18 ist der Fehler der Monitoring-Ergebnisse im Vergleich zu den spectre Simulationsergebnissen gezeigt. Der Fehler bei der Ermittlung des DC-Offsets ist vernachlässigbar klein und befindet sich im Bereich numerischer Berechnungsungenauigkeiten. Auch für die Verstärkung weisen die Monitoring-Ergebnisse eine hohe Genauigkeit auf.

6.1.4. Vorhersage der Restlebenszeit

Für die Vorhersage der Restlebenszeit, bzw. die Extrapolation der zu erwartenden Performance in die Zukunft, kann der Verlauf der Performance durch eine Potenzfunktion modelliert werden, da dies dem zu erwartenden Alterungsverhalten entspricht. Dazu werden die bereits durch das Monitoring ermittelten Performancewerte herangezogen. Die Abschätzung wird umso genauer, je mehr Monitoring-Zyklen berücksichtigt werden. Zu Beginn kann es aufgrund der anfangs

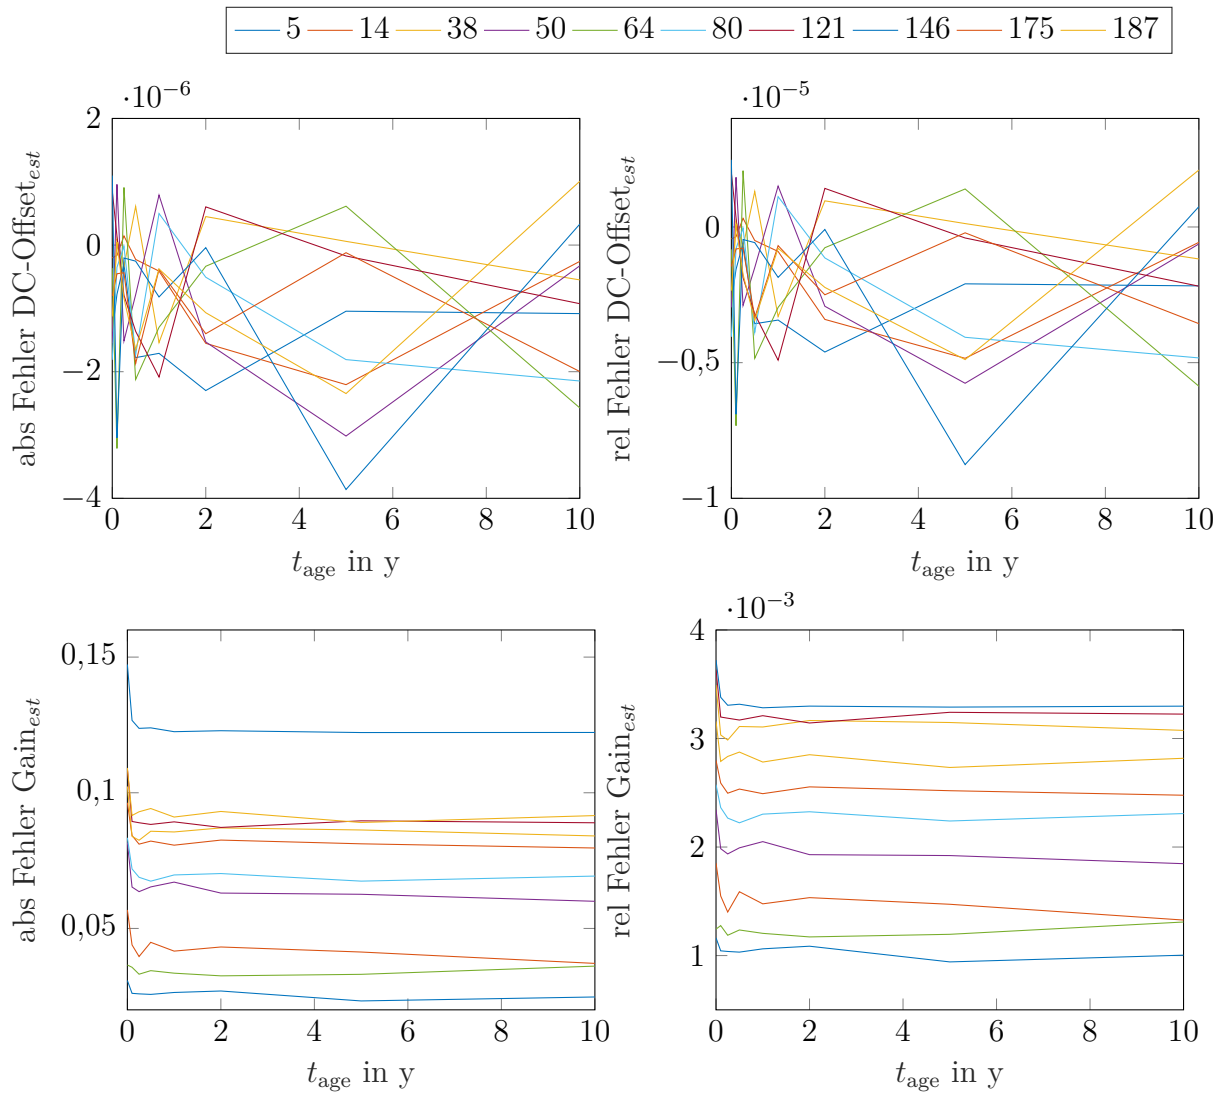


Abbildung 6.18.: Fehler der Monitoring-Ergebnisse im Vergleich zu den direkten Simulationsergebnissen aus spectre. In der Legende sind die gezeigten MC-Punkte aufgeführt.

stärkeren Alterung zu einer Fehleinschätzung der verbleibenden Lebenszeit kommen, wie bspw. bereits in [Hil18] gezeigt wurde. Für die Abschätzung der verbleibenden Restlebenszeit wird die während des Monitoring ermittelte Veränderung der Filterkoeffizienten durch das Potenzgesetz modelliert:

$$w_{ext} = a \cdot t^b + c. \quad (6.1)$$

Voraussetzung für diese Extrapolation ist, dass das Monitoring bei gleichen Bedingungen für Temperatur und Spannung stattfindet. Für die Bestimmung der Parameter a , b und c wird der in MATLAB implementierte Trust-Region-Algorithmus verwendet [MS83]. Zur Berechnung werden mindestens drei Monitoring-Ergebnisse benötigt. Die Extrapolationsergebnisse in Abbildung 6.19 zeigen, dass eine größere Anzahl an Monitoring-Zyklen s nötig ist, um eine

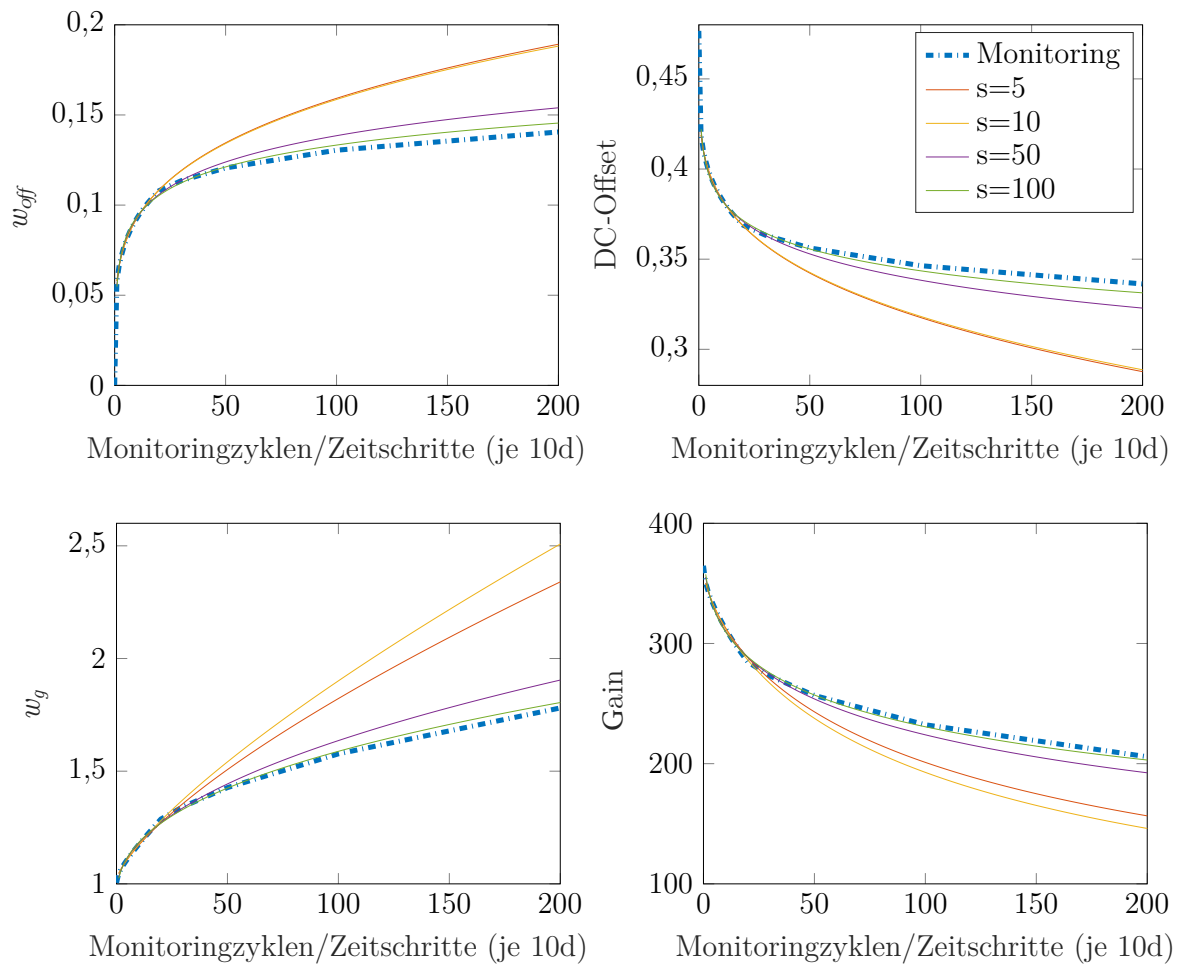


Abbildung 6.19.: Extrapolation der Filterkoeffizienten und sich daraus ergebende Performancewerte für verschiedene Anzahl an berücksichtigten Monitoringzyklen für die Performances des Differentiellen Cascode Opamp unter nominalen Betriebsbedingungen.

stichhaltige Voraussage der Restlebenszeit treffen zu können. Andernfalls kann es zu einer groben Fehleinschätzung der zu erwartenden Degradierung in der Zukunft kommen.

6.2. Messtechnische Evaluation des Monitoring-Verfahrens

Zuvor konnte anhand von Simulationen gezeigt werden, dass mithilfe des entwickelten Monitoring-Verfahrens eine Überwachung der aktuellen Schaltungseigenschaften unter verschiedenen Betriebsbedingungen sowie Prozessvariation möglich ist. Darüber hinaus ermöglicht das Verfahren bei der Überwachung über einen längeren Zeitraum die Detektion von alterungsbedingter Degradierung der überwachten Performances DC-Offset und Verstärkung. In diesem Abschnitt werden nun die Ergebnisse einer messtechnischen Verifikation präsentiert. Dabei erfolgt die Vermessung eines handelsüblichen Operationsverstärkers unter verschiedenen Betriebsbedingungen. Das Monitoring an sich, die Fehlerbestimmung mit den adaptiven Filtern, Ermittlung des Referenzsignals und anschließende Berechnung der tatsächlichen Performance, erfolgt weiterhin in MATLAB Simulink. Die Überwachung von Alterung kann hier nicht messtechnisch verifiziert werden, jedoch wird die Überwachung eines nicht im Verhaltensmodell berücksichtigten Parameters anhand der Temperaturabhängigkeit analysiert.

6.2.1. Testsystem

Das Ziel des Monitoring ist die Überwachung der Eigenschaften einer einzelnen Komponente bzw. Schaltung. Aus diesem Grund wird als Testsystem ein einzelner diskreter handelsüblicher Operationsverstärker herangezogen. Für den zu überwachenden Operationsverstärker gilt dabei die Anforderung, dass die Eigenschaften eine messbare Abhängigkeit von äußeren Einflussfaktoren haben.

Die für die Messung entwickelte Testplatine ist durch das individuelle Anpassen der Widerstände für die Verwendung verschiedener Grundschaltungen konfigurierbar: Open-Loop, Spannungsfolger, invertierend und nicht-invertierend. Hier wird die Konfiguration als Open-Loop verwendet, da in dieser Konfiguration die durch die äußeren Einflüsse hervorgerufenen Veränderungen der Schaltungseigenschaften direkt im Ausgangssignal sichtbar sind. Die Testplatine ist so konzipiert, dass der Testchip durch das Aufstecken auf einer Sockelleiste austauschbar ist. Je nach Gehäuseform ist dafür eine zusätzliche Adapterplatine nötig, wie in Abbildung 6.20 gezeigt. Darüber hinaus befindet sich auf der Testplatine ein Temperatursensor (Thermistor TMP61) mit dazugehöriger Schaltung zur Spannungsregulierung einer konstanten 5V Versorgungsspannung.

Als zu überwachende Komponente wurde der Operationsverstärker LT1813 von *Linear Technology* ausgewählt. Dabei handelt es sich um einen Dualen OPV in Bipolar-Technologie, bei dem sich zwei einzelne Verstärker in einem Gehäuse befinden, hier SO8. Die Verstärkung beträgt laut Datenblatt nominal ca. $A = 67,5$ dB, bei $T = 25$ °C und einem Lastwiderstand von $100\ \Omega$ [LT122]. Das Datenblatt (Anhang B) zeigt zudem eine deutliche Abhängigkeit der Verstärkung von der Temperatur sowie der Größe des Lastwiderstands. Zudem ist die Input-Offset-Spannung ebenfalls temperaturabhängig mit nominell $10\ \mu\text{V}/^\circ\text{C}$. In der hier verwendeten Variante LT1813C für den kommerziellen Einsatz wird garantiert, dass der Verstärker innerhalb eines Temperaturbereichs von 0 bis 70 °C den Spezifikationen entsprechend funktioniert. Bei




Abbildung 6.20.: Testplatine mit austauschbarem OPV LT1813.

darüber hinausgehenden Temperaturen wird eine spezifikationsgerechte Funktionalität nicht garantiert.

6.2.1.1. Verhaltensmodell

Die Simulationen zur Erstellung der RSMs für das Verhaltensmodell werden in *LTSpice* durchgeführt. Die vom Hersteller *LT* bereitgestellten SPICE Simulationsmodelle für den OPV LT1813 enthalten nur begrenzte Abhängigkeiten von äußeren Einflussfaktoren auf das Verhalten der modellierten Komponente. Bei diesen Simulationsmodellen handelt es sich um Makromodelle und nicht um genaue Repräsentationen des OPV auf Transistorebene. So fehlt im Falle des verwendeten LT1813 der im Datenblatt gezeigte Einfluss der Versorgungsspannung auf die Open-Loop Verstärkung. Darüber hinaus enthält das SPICE Modell keine Temperaturabhängigkeit. Dies wird im Folgenden dazu genutzt, um die Möglichkeit der Monitoring-Methode zu demonstrieren, eine nicht durch das Verhaltensmodell abgebildete Einflussgröße zu identifizieren.

Das Verhaltensmodell soll die Abhängigkeiten der Open-Loop Verstärkung von der Versorgungsspannung und dem Lastwiderstand abbilden. Der Einfluss des Lastwiderstands wird durch SPICE Simulationen ermittelt. Aufgrund der beschriebenen Vereinfachungen im SPICE-Modell des OPVs wird darüber hinaus die Abhängigkeit der Verstärkung von der Versorgungsspannung aus dem Datenblatt extrahiert.

In Abbildung 6.21 ist das resultierende RSM der Open-Loop Verstärkung gezeigt. Es handelt sich dabei um eine Matérn2-Funktion mit dem Definitionsbereich $\{2,5 < V_{dd} < 6\}$ V für die Versorgungsspannung und $\{50 < R < 1000\}$ Ω für den Lastwiderstand.




Abbildung 6.21.: Darstellung des erstellten RSM der Open-Loop Verstärkung des OPV LT1813 über Versorgungsspannung V_{dd} und Lastwiderstand, basierend auf SPICE Simulationen und aus dem Datenblatt extrahierten Daten.

Da die Input-Offset-Spannung im Simulationsmodell nicht berücksichtigt wird, gibt es keinen DC-Offset am Ausgang des Verstärkers, der aus einer abweichenden Input-Offset-Spannung resultieren würde. Für das Verhaltensmodell wird der DC-Offset daher als konstant Null angenommen. Im Betrieb können auch geringe Abweichungen der Input-Offset-Spannung zu einem Offset-Fehler am Ausgang führen.

6.2.1.2. Messaufbau

Zum Betrieb der Testschaltung werden eine Spannungsversorgung und ein Funktionsgenerator zur Bereitstellung des Testsignals benötigt. Für die Erzeugung der positiven und negativen Versorgungsspannungen wird die Spannungsquelle *Rigol DP832A* verwendet. Das Testsignal wird durch den 2-Kanal Funktionsgenerator *Rigol DG4062* erzeugt. Beim Testsignal handelt es sich um ein Sinussignal mit einer Amplitude von 1 mV ($V_{pp} = 2$ mV) und einer Frequenz von 500 Hz. Die Aufnahme der Ausgangssignale erfolgt mit dem Digitaloszilloskop *Tektronix DPO7254* mit einer Samplingrate von 100 kS/s .

Die Temperaturmessungen werden in einem Klimaschrank *WEISS WKL 64* durchgeführt, welcher einen Temperaturbereich von -70 bis 180 °C aufweist. Der gesamte Messaufbau ist in der Abbildung 6.22 gezeigt.

Bei der Messung zeigt sich, dass im Ausgangssignal ein 50-Hz-Störsignal vorliegt, welches aufgrund der hohen Verstärkung des OPV zu einer periodischen Schwankung im DC-Offset des Ausgangssignals führt. Um auch das darüber hinaus auftretende Signalrauschen zu minimieren



Abbildung 6.22.: Messaufbau für die Temperaturmessung im Klimaschrank.

und ein verwertbares Signal für das Monitoring zu erhalten, wird für die Aufnahme des Ausgangssignals die Mittelwertbildung (Average-Funktion) des Oszilloskops mit vier Werten verwendet. Aufgrund der Schwankungen des gemessenen Ausgangssignals wird zudem die Anzahl der Datenpunkte zur Ermittlung des gleitenden Mittelwerts zur Bestimmung des Offset-Fehlers innerhalb des Monitoring-Systems erhöht. Dies sorgt für eine bessere Stabilität des Filters zur Bestimmung des Offset-Fehlers und teilweise Unterdrückung des 50-Hz-Störsignals.

6.2.2. Messergebnisse

Im folgenden Abschnitt werden die Ergebnisse der Messungen präsentiert. Zunächst wurde eine Variation der Versorgungsspannung und des Lastwiderstands untersucht. Anschließend erfolgte die Untersuchung des Verhaltens unter Temperatureinfluss, welcher nicht durch das Verhaltensmodell abgebildet wird.

Als Testsignal wird ein Sinussignal mit einer Amplitude von 1mV und einer Frequenz von 500Hz verwendet, welches durch den Funktionsgenerator in die Schaltung eingespeist wird. Das Ausgangssignal wird über einen Zeitraum von 200ms überwacht, wobei während einer Monitoring-Sequenz 20000 Signalwerte verarbeitet werden, was einer Samplingrate von $100kS/s$ entspricht.

Wie zuvor bereits erwähnt, treten während der Messung verschiedene Störfaktoren auf, welche das Messsignal zusätzlich verfälschen. Dabei handelt es sich um Messrauschen sowie ein 50Hz Störsignal auf dem Ausgangssignal des OPVs, welches insbesondere den DC-Offset beeinflusst. Um den Einfluss dieser Faktoren zu minimieren, wurde zum einen die Erfassungsdauer des gleitenden Mittelwerts auf 1000 Werte erhöht. Zudem werden die Schrittweiten der Filter klein gewählt ($\mu_{off} = 0,0005$, $\mu_g = 0,005$), damit diese träger auf kurzfristige Änderungen

Tabelle 6.4.: Input-Offset-Spannungen V_{OS} der acht einzelnen OPVs.

	Chip 1	Chip 2	Chip 3	Chip 4
V_{OS} OPV \square_A	0	0,3	0,4	0,5
V_{OS} OPV \square_B	0,4	-0,1	0,6	0,1

reagieren. Für die Mittelwertbildung der Monitoring-Ergebnisse werden die vergangenen 200 Werte herangezogen, um hier ebenfalls ein stetigeres Ergebnis zu erhalten.

6.2.2.1. Variation von Versorgungsspannung und Lastwiderstand

Zunächst wird das entwickelte Monitoring-Verfahren verwendet, um die initialen Schaltungsperformances des LT1813 zu ermitteln. Insgesamt werden vier Chips für die Messung betrachtet; da es sich bei dem LT1813 um einen Dual-OPV handelt, erfolgt somit die Vermessung von 8 einzelnen OPVs. Diese werden im Folgenden mit OPV $1_{A/B} \dots 4_{A/B}$ bezeichnet, um zu kennzeichnen, welche OPVs auf einem Chip sind. Als Nominalfall wird hier die Konfiguration mit einem Lastwiderstand von 100Ω bei einer Versorgungsspannung von 5 V angenommen. Die Messungen wurden bei einer Raumtemperatur von $24 \text{ }^\circ\text{C}$ durchgeführt, für den Chip 4 erfolgte die Messung der initialen Schaltungsperformance abweichend im Klimaschrank bei einer Temperatur von $20 \text{ }^\circ\text{C}$. Anschließend werden der Lastwiderstand auf 56Ω sowie die Versorgungsspannung auf 6 V variiert, um die dadurch veränderliche Schaltungsperformance zu überwachen. Der OPV ist auch bei geringeren Versorgungsspannungen funktionsfähig, allerdings kommt es dann aufgrund des geringeren zur Verfügung stehenden Spannungsbereichs zu einer Verfälschung des Sinus-Ausgangssignals.

Wie bereits beschrieben, enthält das Verhaltensmodell keine Abhängigkeit der Ausgangs-Offset-Spannung des Verstärkers, da das SPICE-Modell diese ebenfalls nicht beschreibt. Die Input-Offset-Spannung V_{OS} ist die Spannung, welche am Eingang des OPVs als DC-Spannung angelegt werden muss, damit der Ausgang 0 ist bzw. damit ein Sinussignal mittelwertfrei ist. Sie liegt laut Datenblatt bei $0,5 \text{ mV}$ mit einer Variation von bis zu $1,5 \text{ mV}$. Der verwendete Funktionsgenerator hat eine maximale Genauigkeit für den DC-Offset von $100 \mu\text{V}$, wodurch ein Restfehler bei der Einstellung der Input-Offset-Spannung verbleibt. Dieser sorgt für einen DC-Offset des Ausgangssignals des OPVs. Die Input-Offset-Spannung wird so eingestellt, dass der resultierende Ausgangs-DC-Offset im Nominalfall minimal ist. Die entsprechenden Spannungen sind in Tabelle 6.4 dargestellt. Die für den Nominalfall ermittelte Input-Offset-Spannung wird auch bei einer Variation des Lastwiderstands oder der Versorgungsspannung beibehalten, was zu einer Veränderung des DC-Offsets führt.

Abbildung 6.23 stellt die während des Monitoring resultierenden Fehlersignale und Filterkoeffizienten für den Verstärker 1_A bei zwei unterschiedlichen Betriebsbedingungen dar. Im ersten Fall ($R=56\Omega$, 5V) sind lediglich geringe DC-Offset und Verstärkungsfehler vorhanden, während die Abweichungen vom Referenzsignal im zweiten Fall ($R=100\Omega$, 6V) deutlich größer ausfallen. Bei der Betrachtung des DC-Offset-Fehlers ist die beständige Veränderung aufgrund von Mess- und 50Hz -Rauschen deutlich erkennbar. Es ist zudem zu erkennen, dass bei der Bestimmung des Verstärkungsfehlers ein oszillierender Restfehler verbleibt. Zum einen ist hier

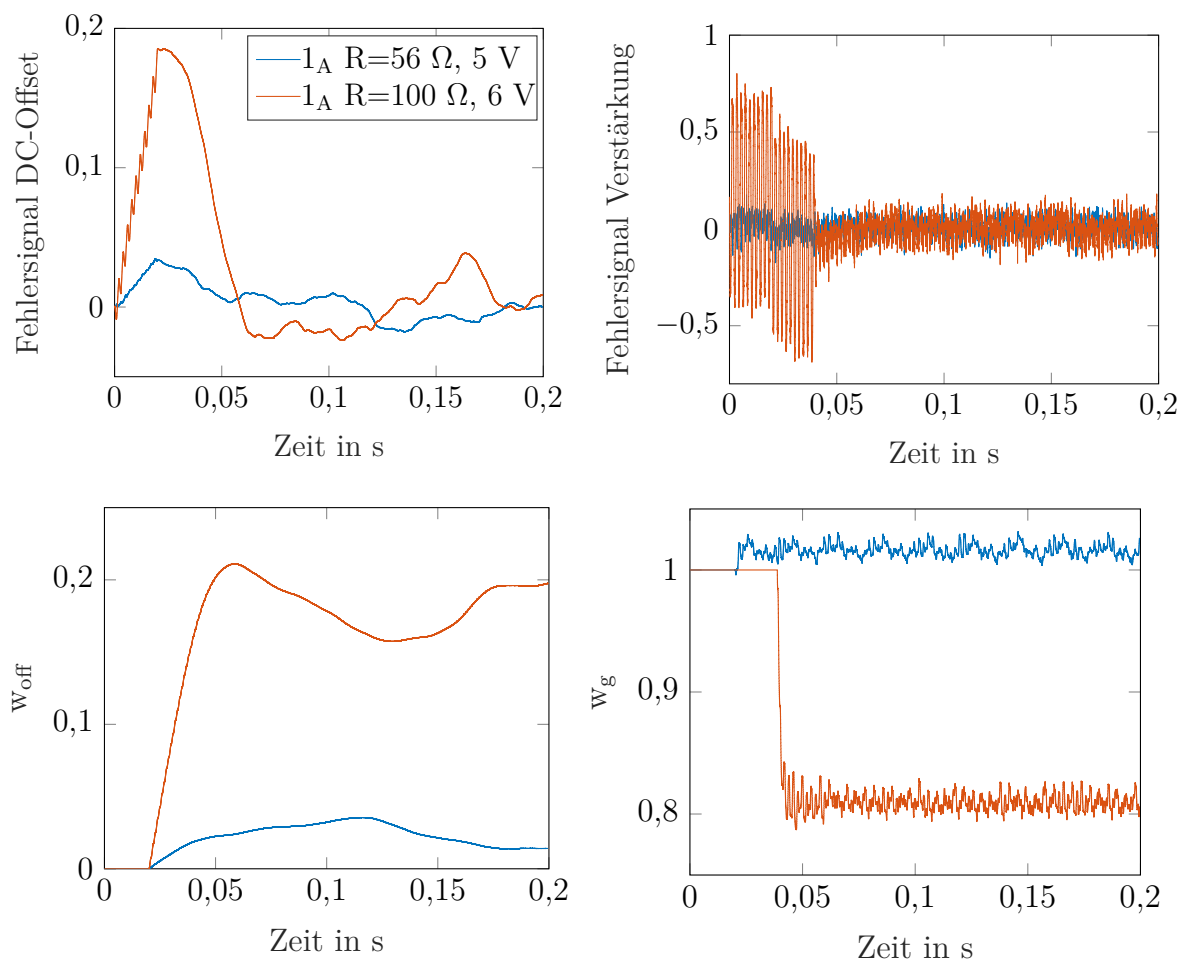


Abbildung 6.23.: Fehlersignale und Filterkoeffizienten für zwei Fälle.

das 50-Hz Rauschen zu sehen, zum anderen stimmen aufgrund von Messrauschen und weiteren Nichtidealitäten das Messsignal und Referenzsignal nie genau überein.

Der zeitliche Verlauf der Monitoring-Ergebnisse ist in Abbildung 6.24 dargestellt. In den Abbildungen für die Verstärkung ist zusätzlich die durch das RSM des Verhaltensmodells berechnete Referenzperformance $gain_{ref}$ eingezeichnet, um die Abweichung zu visualisieren.

Aufgrund von Prozessvariation haben die einzelnen OPVs unterschiedliche Input-Offset-Spannungen, was dementsprechend zu unterschiedlichen DC-Offsets des Ausgangssignals führt. Dabei zeigt sich insbesondere beim ermittelten DC-Offset die zuvor beschriebene Instabilität aufgrund des 50Hz-Rauschens, welches zu einer ständigen Veränderung führt. Bei den Ergebnissen zeigt sich, dass die Input-Offset-Spannung des OPV 4_B offensichtlich nicht optimal gewählt wurde, da hier der resultierende DC-Offset vergleichsweise groß ist.

Auch die Verstärkung unterliegt einer deutlichen Variation aufgrund von Prozessvariation. Zudem ist zu erkennen, dass das Verhalten mitunter stark von den idealen simulierten und durch das Verhaltensmodell repräsentierten Werten abweicht. Dies ist insbesondere bei einem Lastwiderstand von $100\ \Omega$ zu beobachten. Für einen Lastwiderstand von $56\ \Omega$ ist eine gute Übereinstimmung zwischen Modell und Messung erkennbar, hier schwankt der durch das Monitoring

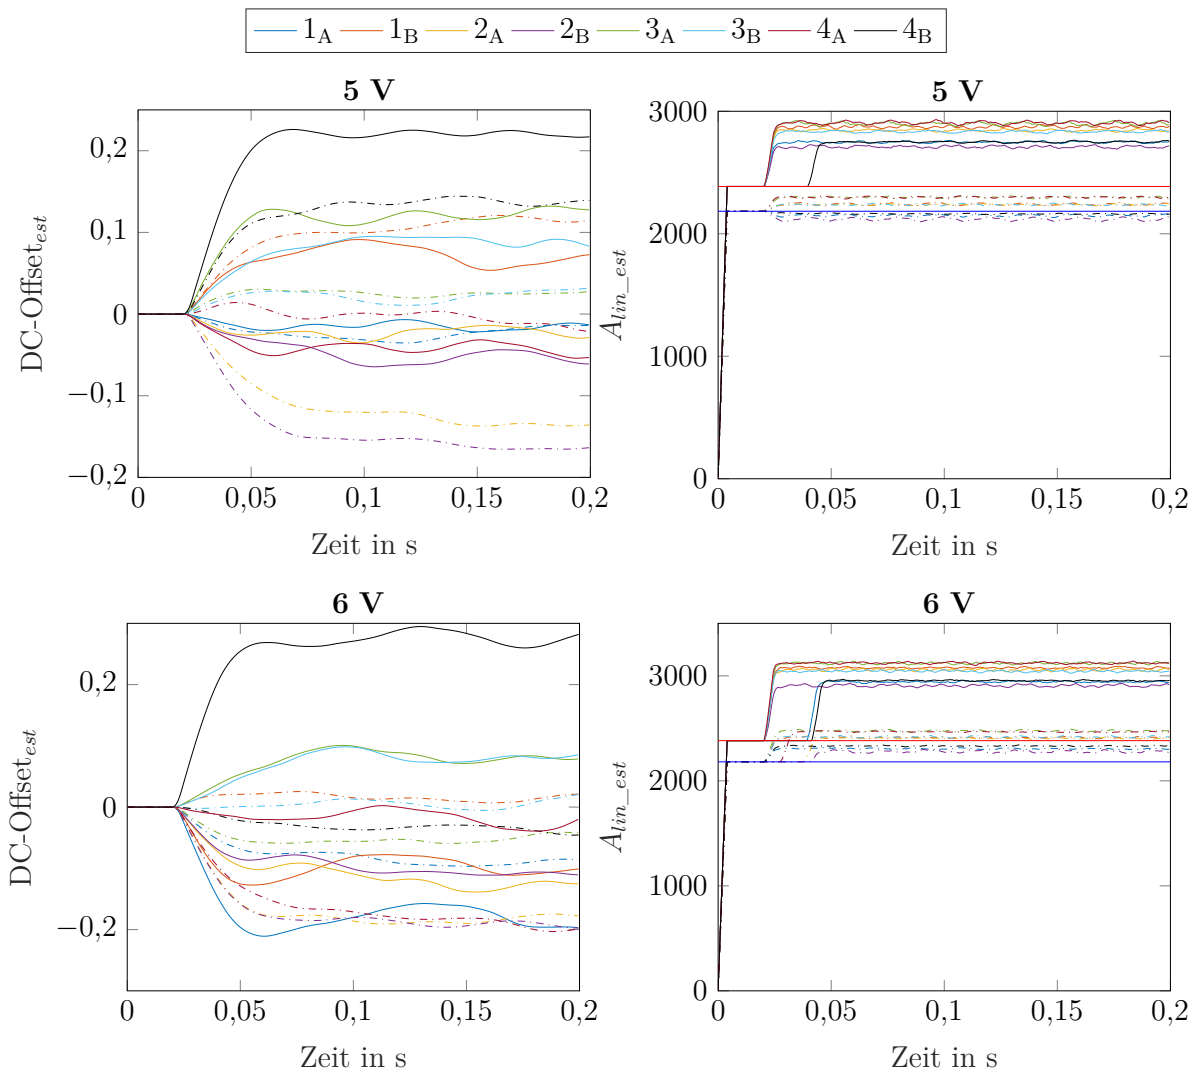


Abbildung 6.24.: Monitoring-Ergebnisse für 4 LT1813 (8 einzelne OPVs) bei verschiedenen Lastwiderständen und Spannungen (gestrichelt: 56Ω , Linie: 100Ω).

ermittelte gemessene Wert aufgrund von Prozessvariation um die ideale Referenzperformance von 2184. Die größeren Abweichungen bei einer Versorgungsspannung von 6V lassen sich durch die zuvor beschriebene Nichtberücksichtigung von Spannungsvariationen im Simulationsmodell erklären. Für das RSM wurde diese Abhängigkeit aus dem Datenblatt extrahiert, was eine zusätzliche Fehlerquelle darstellt.

In Abbildung 6.25 sind die über den Zeitraum $\{100-200\}$ ms gemittelten Monitoring-Ergebnisse für die Verstärkung für alle gemessenen Betriebsbedingungen gezeigt. Dabei sind die Unterschiede zwischen den einzelnen OPVs aufgrund von Prozessvariation sowie die Abhängigkeit von den Betriebsbedingungen noch einmal deutlich zu erkennen. Auch die große Abweichung zu der durch das Verhaltensmodell bestimmten Verstärkung ist dargestellt.




Abbildung 6.25.: Aus dem Monitoring-Ergebnis gemittelte Verstärkung der 8 OPVs bei verschiedenen RL (56 Ω und 100 Ω) und V_{dd} (5 V und 6 V)

6.2.2.2. Variation der Temperatur

Für die Untersuchung des Monitoring bei verschiedenen Temperaturen werden zwei der vier zuvor betrachteten Chips, 3 und 4, im Klimaschrank untersucht. Dabei wird ein Temperaturbereich von -10 bis 90 °C betrachtet. Dieser übersteigt den im Datenblatt spezifizierten Bereich leicht, wodurch eine größere Abweichung vom nominellen Verhalten zu erwarten ist. Der Lastwiderstand befindet sich außerhalb der Temperaturmesskammer, sodass lediglich das Temperaturverhalten des OPV untersucht wird. Die Input-Offset Spannung bleibt konstant auf dem nominellen Wert bei Raumtemperatur aus Tabelle 6.4, sodass die temperaturabhängige Drift der Offset-Spannung überwacht werden kann. Für die Auswertung wird, wie bereits bei der V-R-Messung, eine Mittelwertbildung über den Zeitraum {100 -200} ms der resultierenden Monitoring-Ergebnisse herangezogen.

Zunächst wird das gemessene Temperaturverhalten der OPVs 3_A und 3_B analysiert. Die Messergebnisse bei einem Lastwiderstand von R= 100 Ω und Versorgungsspannungen von V_{dd} = 5 V und V_{dd} = 6 V sind in den Abbildungen 6.26 und 6.27 dargestellt. Die Messung erfolgte hier in 20 °C-Schritten, wobei zusätzlich eine Messung bei 0 °C durchgeführt wurde. Dabei ist sowohl der zeitliche Verlauf der gemittelten Monitoring-Ergebnisse sowie die ermittelten Performancewerte für den DC-Offset und die Verstärkung über der Temperatur gezeigt. Sowohl beim DC-Offset als auch bei der Verstärkung zeigt sich eine deutliche Temperaturabhängigkeit. Als Referenz ist in der Grafik die bei Raumtemperatur (24 °C) gemessene Verstärkung eingezeichnet.

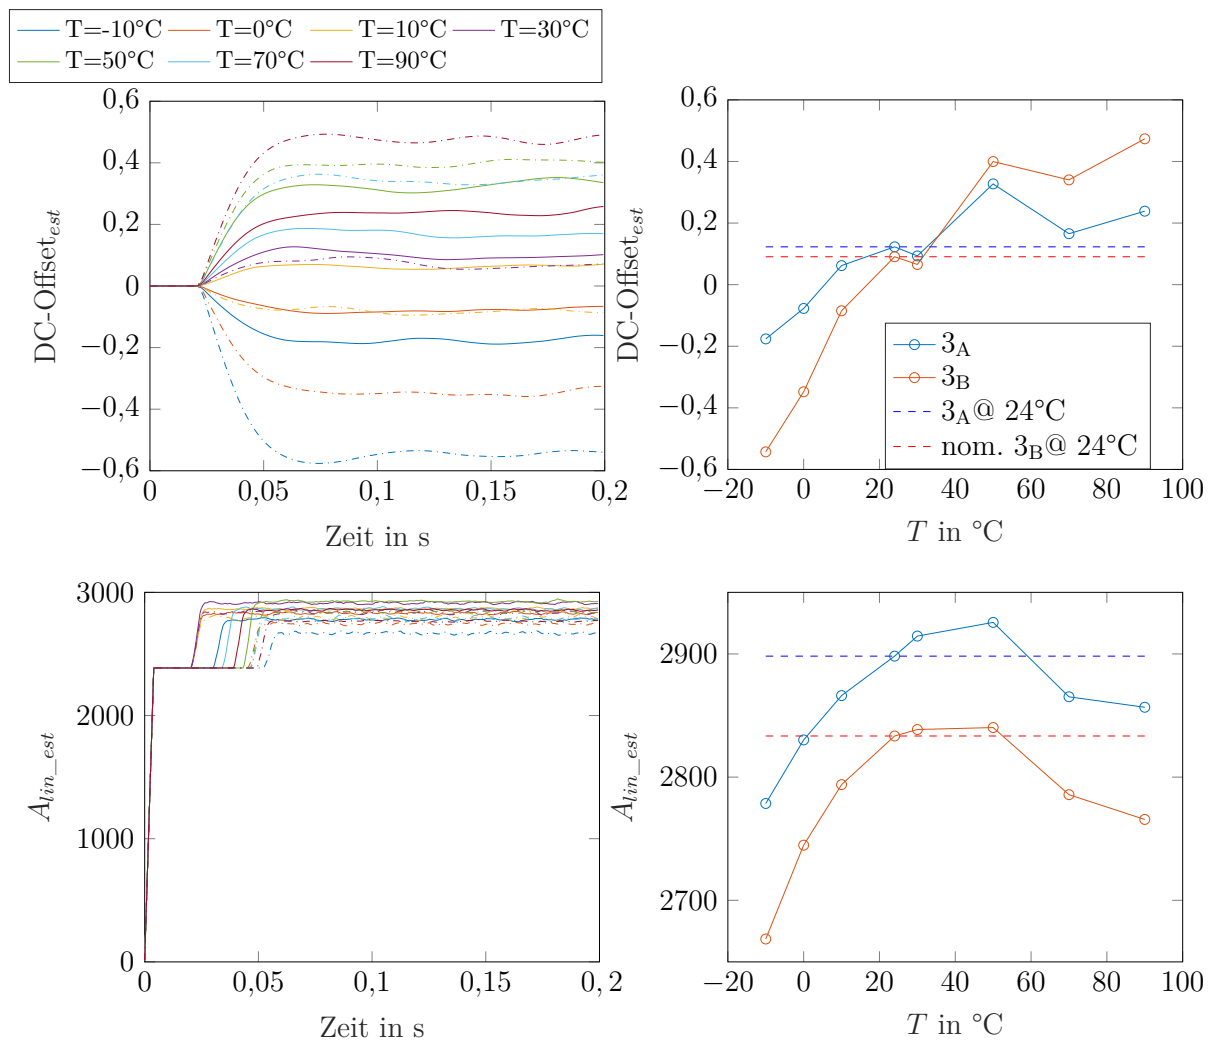


Abbildung 6.26.: Zeitlicher Verlauf der Monitoring-Ergebnisse (Linie: 3_A, gestrichelt: 3_B) und Temperaturverhalten des OPV Nr 3 mit R= 100 Ω bei V_{dd} = 5 V.

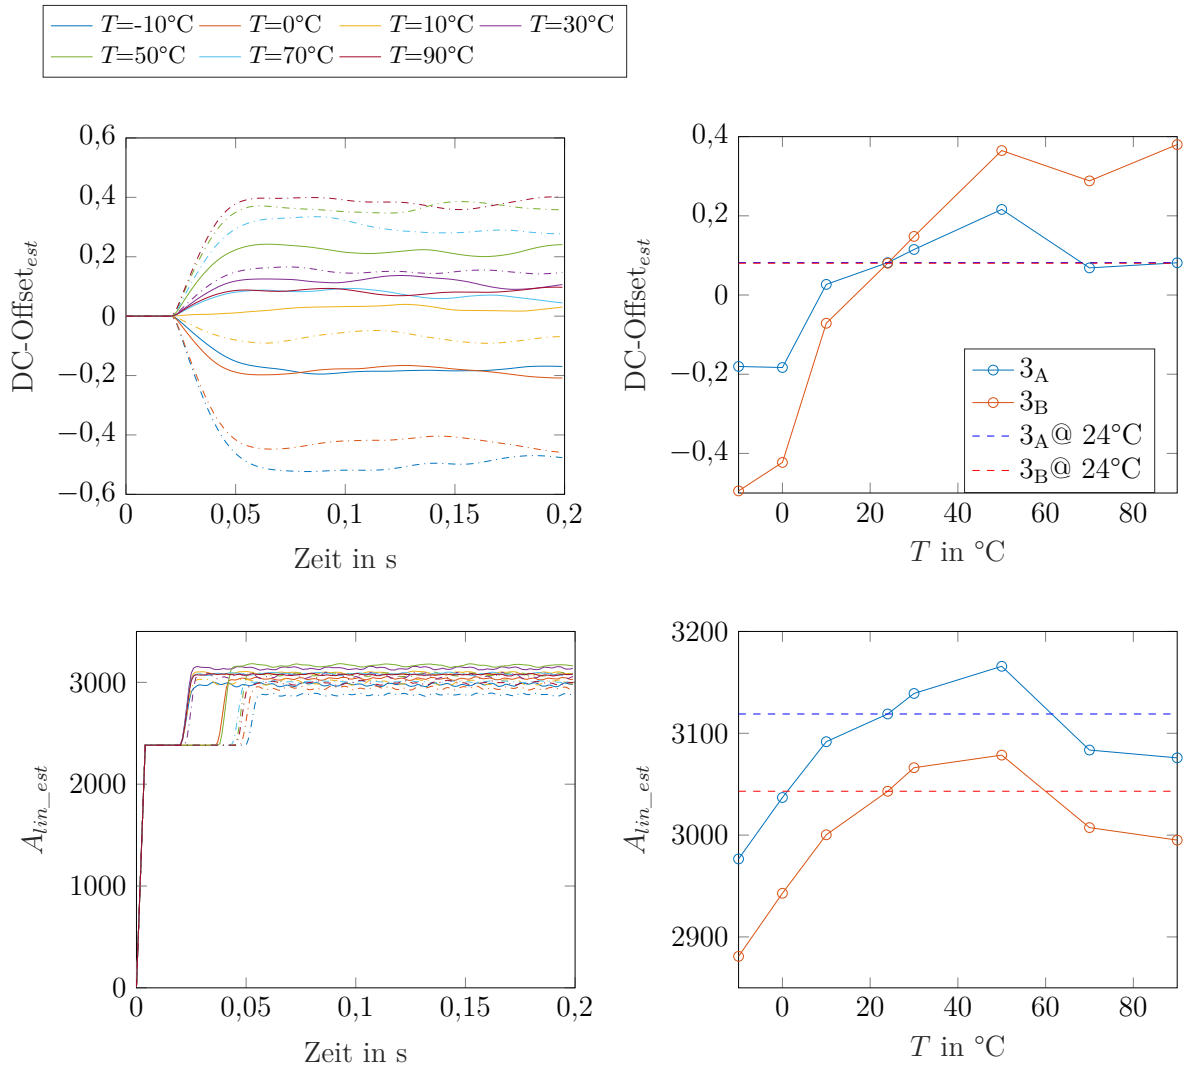


Abbildung 6.27.: Zeitlicher Verlauf der Monitoring-Ergebnisse (Linie: 3_A, gestrichelt: 3_B) und Temperaturverhalten des OPV Nr 3 mit R= 100 Ω bei V_{dd} = 6 V.




Abbildung 6.28.: Vergleich des Temperaturverhaltens des OPV Nr 3 mit $R= 100 \Omega$ bei $V_{dd} = 5$ V und $V_{dd} = 6$ V.

Der ermittelte DC-Offset zeigt einen annähernd linearen Anstieg mit der Temperatur. Die Eingangs-Offset-Spannung hat laut Datenblatt eine maximale Veränderung (*Input Offset Voltage Drift*) von $30 \mu V/^\circ C$. Da die Eingangs-Offset-Spannung während der Temperaturmessung nicht nachgeregelt wurde, zeigt sich diese Veränderung hier in dem Ausgangs-DC-Offset. Bei der Ermittlung des DC-Offset zeigen sich teils stärkere Schwankungen, welche auf Messungenauigkeiten sowie insbesondere auf die zuvor beschriebenen Fehler durch zusätzliches Rauschen (50-Hz-Störung) zurückgeführt werden können. Die Verstärkung zeigt insgesamt das gemäß Datenblatt zu erwartende Temperaturverhalten, wobei bei höheren Temperaturen eine stärkere Abnahme der Verstärkung gemessen wurde.

Ein direkter Vergleich der durch das Monitoring ermittelten Performancewerte für das DC-Offset und die Verstärkung bei den unterschiedlichen Betriebsbedingungen über der Temperatur ist in Abbildung 6.28 dargestellt. Dabei zeigt sich deutlich die aufgrund von Prozessvariation auftretende Variation zwischen den einzelnen OPVs.

In Abbildung 6.29 sind die Monitoring-Ergebnisse für die Temperaturmessung des OPV Nr. 4 gezeigt mit $R= 100 \Omega$ bei $V_{dd} = 5$ V. Die Messung für diesen OPV erfolgte in $10^\circ C$ -Schritten. Die Verstärkung zeigt wie zuvor den erwarteten Temperaturverlauf mit dem auch bei OPV Nr. 3 beobachteten Abfall der Verstärkung bei höheren Temperaturen. Ein anderes Verhalten ist bei der Ermittlung des DC-Offset zu erkennen. Bei dem Ausreißer bei $10^\circ C$ kann von einem Messfehler ausgegangen werden, ebenso scheint das Sinken des DC-Offsets bei hohen Temperaturen für 4_A nicht plausibel. Zudem ist für den OPV 4_B ein invertiertes Temperaturverhalten erkennbar. Dies liegt möglicherweise an der zuvor nicht optimal gewählten V_{OS} .

Abschließend wird ein Vergleich des durch das Monitoring ermittelten Temperaturverhaltens der OPVs 3 und 4 bei einer Versorgungsspannung von 5V in Abbildung 6.30 durchgeführt.

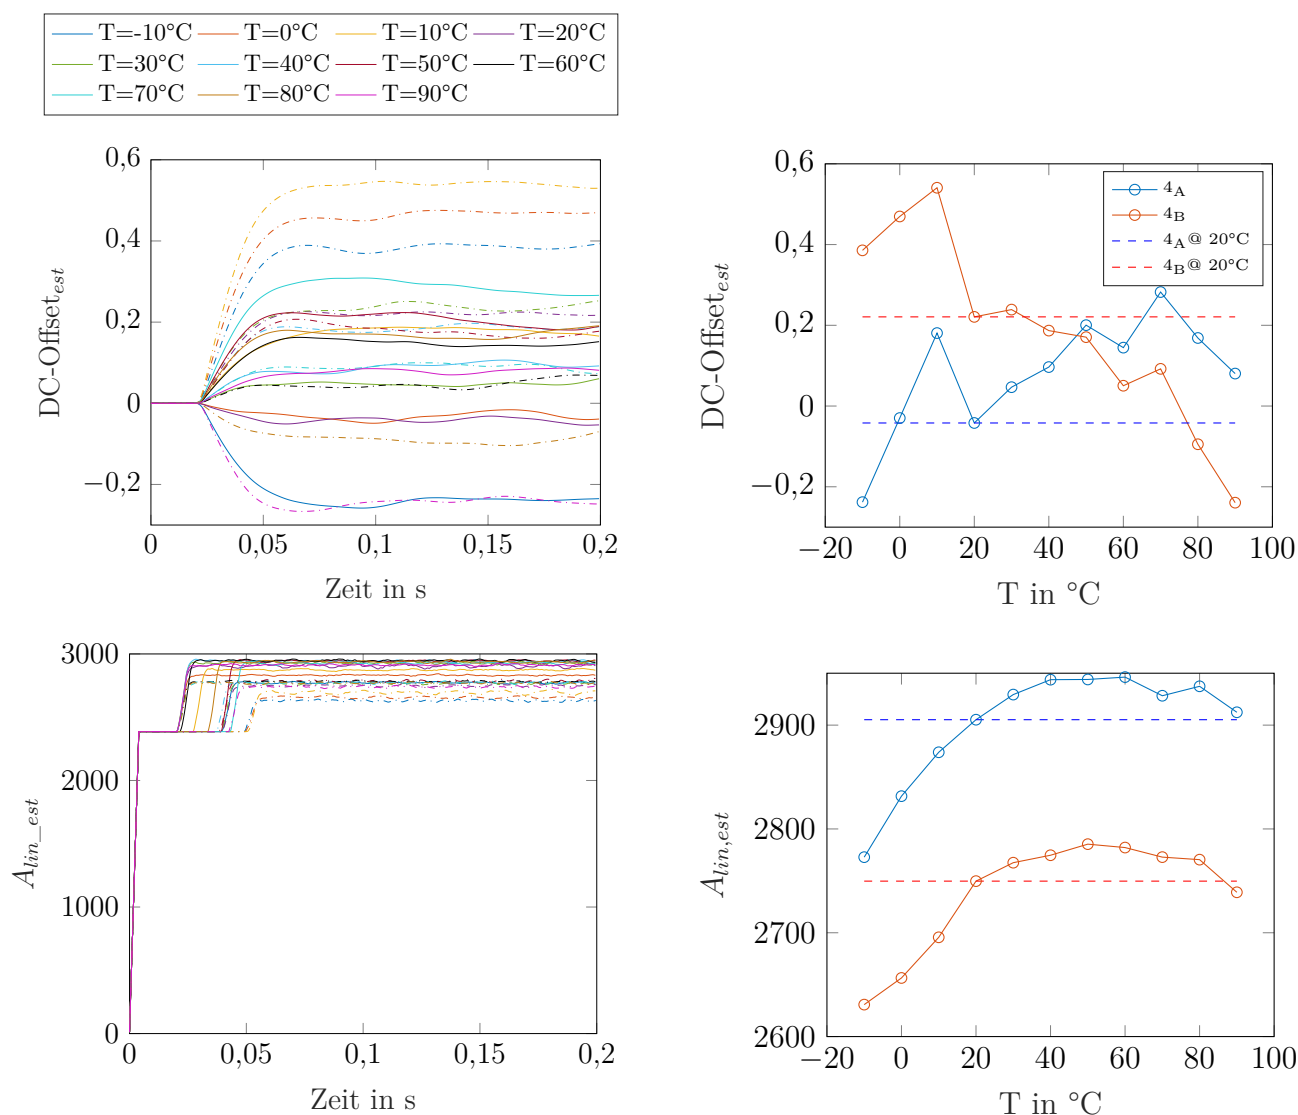


Abbildung 6.29.: Zeitlicher Verlauf der Monitoring-Ergebnisse (Linie: 4_A, gestrichelt: 4_B) und Temperaturverhalten des OPV Nr 4 mit $R = 100 \Omega$ bei $V_{dd} = 5 \text{ V}$.

Hierbei zeigt sich erneut die Variation der Verstärkungswerte durch Prozessschwankungen sowie das insgesamt übereinstimmende Temperaturverhalten der einzelnen OPVs.

Durch die hier analysierte Ermittlung des Temperaturverhaltens wurde gezeigt, dass das entwickelte Monitoring-Verfahren in der Lage ist, die Veränderung durch eine nicht im Verhaltensmodell modellierte weitere Einflussgröße zu überwachen. An dieser Stelle ist festzuhalten, dass das Monitoring-Verfahren trotz der vorliegenden Messungenauigkeiten und zusätzlichen 50 Hz-Störung in der Lage ist, \mathcal{P}_{est} zu bestimmen.




Abbildung 6.30.: Vergleich des Temperaturverhaltens der Verstärkung von OPV 3 und 4.

6.3. Zusammenfassung

In diesem Abschnitt wurde die Funktionalität des entwickelten Monitoring-Verfahrens zur Ermittlung der aktuellen Schaltungsperformance sowie zur Überwachung von Degradation anhand von Simulationen und Messungen analysiert. Es wurde gezeigt, dass das Monitoring unter der Berücksichtigung von PVTA-Einflüssen mithilfe des Verfahrens möglich ist und die aktuelle Schaltungsperformance hinreichend genau ermittelt werden kann. In der messtechnischen Untersuchung zeigte sich zudem, dass das Verfahren auch bei auftretenden Störungen, hier einem 50-Hz-Störsignal arbeitet und gute Ergebnisse liefert. Darüber hinaus kann die Restlebenszeit anhand der bisherigen Monitoring-Ergebnisse abgeschätzt werden, indem eine Extrapolation durchgeführt und ermittelt wird, ob und wann die gegebenen Spezifikationsgrenzen erreicht werden. Dies ermöglicht bei einer Anwendung in sicherheitskritischen Systemen die Möglichkeit zur frühzeitigen Reaktion auf einen möglichen bevorstehenden Ausfall.

7.1. Zusammenfassung

In der vorliegenden Arbeit wurden zunächst Modellierungsverfahren zur Erstellung stochastischer Performance- und Verhaltensmodelle vorgestellt. Diese basieren auf der Verwendung von Response-Surface-Modellen zur Modellierung der Abhängigkeit der Performances einer Schaltung von verschiedenen Umgebungs- und Eingangsvariablen. Die RSMs modellieren dabei die Verschiebung der Kenngrößen (Mittelwert und Standardabweichung) der durch Prozessvariation hervorgerufenen stochastischen Verteilung einzelner Schaltungsperformances. Darüber hinaus kann die Alterung der Schaltungsperformance durch HCI und BTI berücksichtigt werden, welche eine Verschiebung der Verteilung über die Zeit bewirkt. Für normalverteilte Performancevariationen ermöglicht die zusätzliche Modellierung des Korrelationskoeffizienten die Berücksichtigung von einfachen Korrelationen zwischen Subsystemen, womit eine hierarchische Modellierung realisiert werden kann. Neben der Berücksichtigung parametrischer Verteilungen wie der Normal- und Lognormalverteilung, wurde auch eine Modellierung zur Erfassung beliebig geformter Verteilungen entwickelt. Dabei wird die Verteilungsdichtefunktion der Performanceverteilung durch ein Gaussian Mixture Modell bestimmt. Aus dieser Modellierung kann zum einen ein LUT-basiertes stochastisches Performancemodell abgeleitet werden, welches die Koeffizienten des GMM beinhaltet. Zum anderen kann die Verteilung durch ein RSM modelliert werden.

Die einzelnen Modellierungsverfahren wurden zu einer umfassenden Modellierungsmethodik zusammengefasst, welche die Berücksichtigung der verschiedenen betrachteten Verteilungen ermöglicht. Die erstellten Verhaltensmodelle erlauben die Betrachtung der Performancevariation unter verschiedenen Umgebungsbedingungen auf höherer Abstraktionsebene und können bspw. für die Untersuchung der Zuverlässigkeit eines größeren Gesamtsystems verwendet werden. Für die Erstellung der Modelle aus Simulations- oder Messdaten wurde zudem die MATLAB-Applikation ReSeMBleD entwickelt. Basierend auf einer bestehenden Anwendung wurde diese grundlegend neu implementiert und ermöglicht neben der automatisierten Simulationskontrolle die Berechnung der für die hier entwickelten stochastischen Performancemodelle benötigten RSMs.

Die beschriebenen Modellierungsverfahren wurden anhand verschiedener Beispielschaltungen simulationsbasiert analysiert. Dabei zeigt sich, dass durch die entwickelten Verfahren eine gute

Genauigkeit bei der Repräsentation der Performanceverteilungen sowie ihrer Veränderung über verschiedene Betriebsbedingungen erreicht werden kann.

Im zweiten Teil der Arbeit wurden Verhaltensmodelle verwendet, um ein auf der Auswertung der Filterkoeffizienten adaptiver Filter basierendes Monitoring-Verfahren zu entwickeln. Das RSM-basierte, nicht-stochastische Verhaltensmodell der zu überwachenden Schaltung wird dazu verwendet, um das vom adaptiven Filter benötigte Referenzsignal zu bestimmen. Durch die im Verhaltensmodell berücksichtigten Abhängigkeiten von den Umgebungsparametern Temperatur und Versorgungsspannung, entspricht das Referenzsignal somit dem ideal zu erwartenden Ausgangssignal der Schaltung. Abweichungen zwischen dem realen Ausgangs- und dem Referenzsignal sind durch das adaptive Filter korrigierbar. Die resultierenden Filterkoeffizienten wurden anschließend genutzt, um mithilfe der vom RSM-Verhaltensmodell berechneten idealen Performances die realen Performancewerte der Schaltung zum aktuellen Zeitpunkt zu bestimmen. Damit kann durch das Monitoring sowohl die initial vorliegende Abweichung aufgrund von Prozessvariation, als auch die aktuellen Performanceparameter bei wechselnden Betriebsbedingungen ermittelt werden. Wird die Überwachung über einen längeren Zeitraum durchgeführt, können aufgrund der zeitlichen Veränderung zudem Rückschlüsse über die Degradierung gezogen werden. Dies ermöglicht auch eine Abschätzung der Restlebenszeit der Schaltung. Das entwickelte Monitoring-Verfahren wurde anhand von Beispielschaltungen simulativ evaluiert, wobei sowohl Prozessvariation als auch alterungsbedingte Degradierung erfolgreich überwacht werden konnten. Darüber hinaus erfolgte neben der simulationsbasierten Analyse eine messtechnische Validierung anhand einer Operationsverstärkerschaltung. Das Monitoring erfolgte dabei für mehrere Bauteile zur Erfassung von Prozessvariation sowie unter Spannungs- und Temperaturschwankungen in einem Klimaschrank.

7.2. Ausblick

Die im Rahmen dieser Arbeit entwickelten Methoden zur Erstellung stochastischer Verhaltensmodelle ermöglichen die Modellierung verschiedener Verteilungen und ihrer Abhängigkeit von weiteren Umgebungsbedingungen. Darüber hinaus sind in verschiedenen Bereichen Weiterentwicklungen denkbar.

Es existieren bereits verschiedene Optimierungsmethoden für die verwendeten RSMs, welche im Rahmen dieser Arbeit nur teilweise berücksichtigt wurden, bspw. durch die Verwendung adaptiver Samplingverfahren. Eine weitere Optimierung kann hier zu einer Verbesserung der Genauigkeit der resultierenden Performancemodelle führen. Bei der Modellierung stochastischer Verteilungen wurde hier ein einfaches Verfahren zur Berücksichtigung von Korrelationen beschrieben, welches auf der Korrektur der Standardabweichung bei der hierarchischen Modellierung basiert. Das Verfahren zeigt eine signifikante Verbesserung in der Repräsentation der Verteilung, der verbleibende Modellierungsfehler kann jedoch eventuell durch weiterführende Anpassungen der Modellierung reduziert werden. Für die Erfassung multivariater Korrelationen werden zudem komplexere Methoden benötigt. Eine Möglichkeit bieten hier bspw. die Copula-Funktionen [Nel06]. Es bestehen bereits Ansätze für derartige Modellierungen, interessant wäre hier, diese in Kombination mit den in dieser Arbeit vorgestellten RSM-basierten

Modellierungsverfahren zu betrachten. Darüber hinaus erfolgt bei der Modellierung der durch GMM bestimmten nicht-normalen Verteilungen durch RSMs keine Berücksichtigung der stochastischen Eigenschaften, wodurch diese lediglich eine grobe Abschätzung der zu erwartenden Verteilung liefert. Hier können weitere Modellierungsverfahren untersucht werden, die eine stetige Abbildung der multidimensionalen Verteilung ermöglichen.

Das entwickelte Monitoring-Verfahren ermöglicht die Ermittlung der aktuellen Schaltungsperformance anhand der Koeffizienten eines adaptiven Filters. Hier wurde der LMS-Algorithmus als einfacher Filteralgorithmus verwendet, welcher gute Ergebnisse liefert. Trotzdem könnten zur Verbesserung des Monitoring optimierte LMS- oder weitere Filteralgorithmen untersucht werden. Darüber hinaus kann auch die messtechnische Betrachtung des Degradationsmonitoring sowie die Untersuchung anderer Schaltungstypen in Betracht gezogen werden, um die Übertragbarkeit des Monitoring-Verfahrens zu evaluieren. Im Bezug auf das entwickelte Monitoring-Verfahren ist zudem die technische Umsetzung von Interesse. Hier können zum einen Hardwareimplementierungen auf einem FPGA oder DSP als auch die Untersuchung integrierter ASIC-Lösungen berücksichtigt werden. Eine weitere Herausforderung stellt das Design entsprechend robuster Temperatur- und Spannungssensorik dar, welche für das Monitoring benötigt wird.

A

Dimensionierung der Beispielschaltungen

In diesem Abschnitt sind die Dimensionierungen der verwendeten Beispielschaltungen gezeigt. Die Dimensionierung basiert auf in [Bak10] gegebenen Schaltungen. Darüber hinaus werden die verwendeten Bias-Quellen mit ihren Dimensionierungen dargestellt. Alle nicht explizit benannten Transistoren haben die in den Tabellen unter PMOS bzw. NMOS gegebenen Dimensionen.

A.1.2. Distributionsnetzwerk

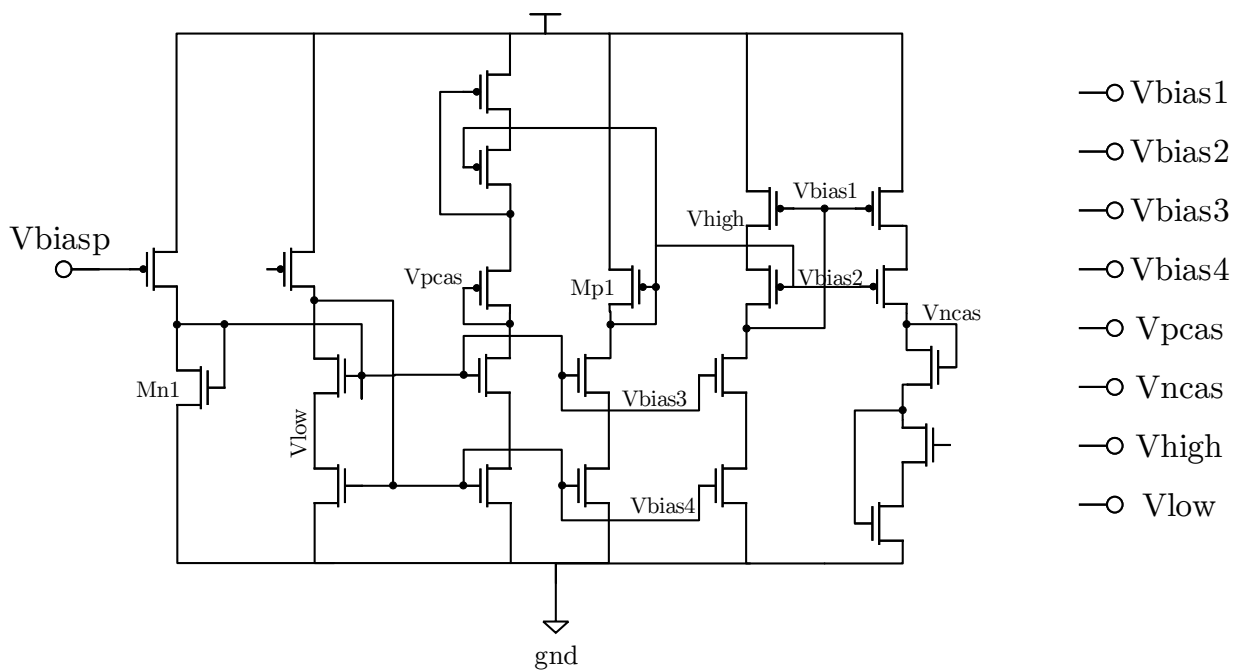


Abbildung A.2.: Aufbau des Distributions- (Bias-) Netzwerks.

Tabelle A.2.: Dimensionierung des Bias-Netzwerks.

Bauteil	W [nm]	L [nm]
PMOS	6000	120
NMOS	6000	120
Mp1	1200	600
Mn1	600	600

A.2. Differentieller Cascode-Operationsverstärker




Abbildung A.4.: Aufbau des differentiellen Cascode-Operationsverstärkers.

Tabelle A.4.: Dimensionierung des differentiellen Cascode-Operationsverstärkers.

Bauteil	W [nm]	L [nm]
PMOS	900	60
NMOS	300	60
M_D	300	240

A.3. Folded-Cascode-Operationsverstärker

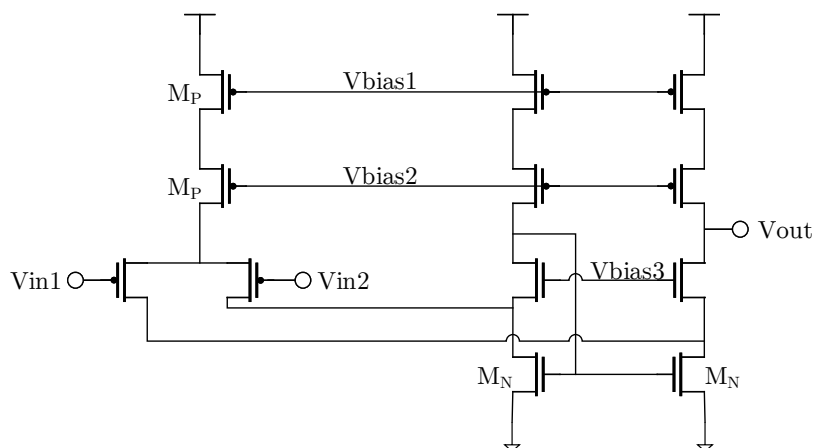


Abbildung A.5.: Aufbau des Folded-Cascode-Operationsverstärkers.

Tabelle A.5.: Dimensionierung des Folded-Cascode-Operationsverstärkers.


Bauteil	W [nm]	L [nm]
PMOS	900	60
NMOS	300	60
M_P	1800	60
M_N	600	60



Auszug des Datenblatts
LT1813


TYPICAL PERFORMANCE CHARACTERISTICS

Supply Current vs Temperature




1813/14 G01

Input Common Mode Range vs Supply Voltage




1813/14 G02

Input Bias Current vs Common Mode Voltage




1813/14 G03

Input Bias Current vs Temperature




1813/14 G04

Input Noise Spectral Density




1813/14 G05

Open-Loop Gain vs Resistive Load




1813/14 G06

Open-Loop Gain vs Temperature




1813/14 G07

Output Voltage Swing vs Supply Voltage




1813/14 G02

Output Voltage Swing vs Load Current



1813/14 G09




Abkürzungsverzeichnis

ADC	Analog-Digital-Konverter
AMS	Analog-Mixed-Signal
ATE	<i>Automatic Test Equipment</i>
BERT	<i>Berkeley Reliability Tools</i>
BIC	Bayes'sche-Informationskriterium
BIST	<i>Built-In Self Test</i>
BSIM	<i>Berkeley Short-channel IGFET Model</i>
BTI	<i>Bias Temperature Instability</i>
BBD	Box-Behnken Design
CCD	Central Composite Design
CDF	<i>cumulative distribution function</i> / kumulative Verteilungsfunktion
CMOS	<i>Complementary Metal-Oxide-Semiconductor</i>
CUT	<i>Circuit under Test</i>
DfR	<i>Design for Reliability</i>
DFT	<i>Design for Test</i>
DoE	<i>Design of Experiments</i> / statistische Versuchsplanung
EM	Elektromigration
FinFET	Fin Field-Effect Transistor
FIR	<i>Finite Impulse Response</i>
GUI	<i>Graphical User Interface</i>
GMM	<i>Gaussian Mixture Model</i>
HCD	<i>Hot Carrier Degradation</i>
HCI	<i>Hot Carrier Injection</i>
KDE	<i>Kernel Density Estimation</i>

KS-Test	Kolmogorow-Smirnow-Test
LDS	<i>Low discrepancy Sequence</i>
LER/LWR	<i>Line-edge- und Line-width-Roughness</i>
LHS	<i>Latin Hypercube Sampling</i>
LMS	<i>Least-Mean-Square</i>
LUT	<i>Look-Up Table</i>
MAE	<i>Mean absolute error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
maxAE	<i>Maximum absolute Error</i>
MC	Monte Carlo
MCMC	Markov-Chain-Monte-Carlo
MOS	<i>Metal-Oxid-Semiconductor</i>
MOSFET	Metal-Oxid-Semiconductor Fieldeffect Transistor
NBTI	<i>Negative Bias Temperature Instability</i>
NLMS	<i>normalized Least-Mean-Square</i>
OPV	Operationsverstärker
OTA	<i>Operational Transconductance Amplifier</i>
PBTI	<i>Positive Bias Temperature Instability</i>
PDF	<i>probability density function</i> / Wahrscheinlichkeitsdichtefunktion
PDK	<i>Process Design Kit</i>
PVTA	<i>Process, Voltage, Temperature, Aging</i>
RBF	Radiale Basisfunktion
RDF	Random Dopant Fluctuation
RLS	<i>Recursive Least Squares</i>
RNM	<i>Real Number Model(ing)</i>
RSM	Response Surface Modell
RUL	<i>Remaining Useful Lifetime</i>
SP	Stütz-/Samplepunkt
SPM	Stochastisches Performancemodell
SPICE	<i>Simulation Program with Integrated Circuit Emphasis</i>
SVM	Stochastisches Verhaltensmodell
SVM	<i>Support Vector Machine</i>


TDDDB	<i>Time Dependent Dielectric Breakdown</i>
TDV	<i>Time Dependent Variability</i>
TP	Testpunkt
TZV	<i>Time Zero Variability</i>
VHDL	<i>Very High Speed Integrated Circuit Hardware Description Language</i>
VM	Verhaltensmodell
VTA	<i>Voltage, Temperature, Aging</i>



Symbolverzeichnis

Symbol	Bezeichnung
β	Koeffizienten der Approximationsfunktion
c	Formparameter
C_{OX}	Oxidkapazität
d	Umgebungsparameter
d	Referenzsignal (adapt. Filter)
e	Fehlersignal (adapt. Filter)
e_g	Fehlersignal Verstärkung
e_{off}	Fehlersignal DC-Offset
ϵ_{ox}	relative Permittivität des Oxids
ϵ_{RSM}	Modellfehler des RSM
ϵ_{si}	relative Permittivität des Siliziums
ϵ_{VM}	Modellfehler des Verhaltensmodells
F	Matrix der Stützpunkte
i	Eingangssignale
IDS	Drain-Source-Strom
k	Boltzmann-Konstante
L	Kanallänge
L_{eff}	effektive Kanallänge
λ	Kanallängenmodulationsfaktor
m	Anzahl Performances
μ	Ladungsträgerbeweglichkeit
μ	Mittelwert
n	Anzahl Stützpunkte/stellen
\mathcal{N}	Normalverteilung
N_b	Dotierkonzentration im Bulk
n_i	intrinsische Ladungsträger
N_C	effektive Zustandsdichte im Leitungsband
N_T	Anzahl Testpunkte
N_V	effektive Zustandsdichte im Valenzband

p, \mathbf{p}	Modellparameter
\hat{p}	Stützstelle
\tilde{p}	normierte Stützstelle
\mathcal{P}	Schaltungseigenschaft, Performance
ϕ	Radiale Basisfunktion
ϕ_b	Bulk-Potential
ϕ_F	Fermi-Potential
q	Elementarladung
R_{\square}	Zuverlässigkeitsfunktion
ρ	Korrelationskoeffizient
σ	Standardabweichung
t	Zeit
T	Temperatur
t_{age}	Alter
TCV_{th}	Temperaturkoeffizient der Schwellspannung
t_{OX}	Oxiddicke
u, \mathbf{u}	Filtereingangssignal (adapt. Filter)
V_{dd}	Versorgungsspannung
V_{DS}	Drain-Source-Spannung
$V_{\text{DS, sat}}$	Drain-Source Sättigungsspannung
V_{GS}	Gate-Source-Spannung
V_{ref}	Referenzspannung
V_{th}	Schwellspannung
w	Filterkoeffizient (adapt. Filter)
W	Transistorweite
W_{eff}	effektive Weite
w_g	Filterkoeffizient für Verstärkung (adapt. Filter)
W_g	Bandabstand
w_i	Gewichte des GMM
w_{off}	Filterkoeffizient für DC-Offset (adapt. Filter)
\mathbf{X}	Matrix der Stützstellen
y	Ausgangssignal



Literaturverzeichnisse

Referenzen

- [AKB03] Asen Asenov, Savas Kaya, and Andrew R Brown. Intrinsic parameter fluctuations in decananometer MOSFETs introduced by gate line edge roughness. *IEEE Transactions on Electron Devices*, 50(5):1254–1260, 2003.
- [AKD02] Asen Asenov, Savas Kaya, and John H Davies. Intrinsic threshold voltage fluctuations in decanano MOSFETs due to local oxide thickness variations. *IEEE Transactions on electron devices*, 49(1):112–119, 2002.
- [Art18] Art Schaldenbrand (Cadence Design Systems). Re-Thinking Reliability Analysis. *7th International Workshop on Analogue and Mixed-Signal Integrated Circuits for Space Applications (AMICSA)*, 2018.
- [Ary15] Nasim Pour Aryan. *Monitoring Concepts for Degradation Effects in Digital CMOS Circuits*. PhD thesis, Technischen Universität München, 2015.
- [Bak10] R. Jacob Baker. *CMOS: circuit design, layout, and simulation*. IEEE Press series on microelectronic systems ; [9]. IEEE Press [u.a.], Piscataway, NJ [u.a.], 3. ed. edition, 2010. XXXIII, 1173 S. : Ill., graph. Darst.
- [BAS11] Dharmendar Boolchandani, Abrar Ahmed, and Vineet Sahula. Efficient kernel functions for support vector machine regression model for analog circuits' performance evaluation. *Analog Integrated Circuits and Signal Processing*, 66(1):117–128, 2011.
- [BB60] George EP Box and Donald W Behnken. Some new three level designs for the study of quantitative variables. *Technometrics*, 2(4):455–475, 1960.
- [BCO16] Dariusz Bismor, Krzysztof Czyz, and Zbigniew Ogonowski. Review and comparison of variable step-size LMS algorithms. *International Journal of Acoustics and Vibration*, 21(1):24–39, 2016.
- [BD87] George E. P. Box and Norman R. Draper. *Empirical Model-Building and Response Surfaces*. John Wiley & Sons, 1987.

- [BGK⁺10] Zdravko I Botev, Joseph F Grotowski, Dirk P Kroese, et al. Kernel density estimation via diffusion. *The Annals of Statistics*, 38(5):2916–2957, 2010.
- [BVR11] Manuel J Barragán, Diego Vázquez, and Adoración Rueda. Analog sinewave signal generators for mixed-signal built-in test applications. *Journal of Electronic Testing*, 27(3):305–320, 2011.
- [Cad] Cadence Design Systems. *Spectre Classic Simulator, Spectre Accelerated Parallel Simulator (APS), and Spectre Extensive Partitioning Simulator (XPS) User Guide*, product version 18.1 edition.
- [Cad18a] Cadence Design Systems. *Spectre RelXpert Reliability Simulator User Guide*, product version 18.1 edition, 2018.
- [Cad18b] Cadence Design Systems. *Virtuoso ADE Explorer User Guide*, product version ic6.1.8 edition, 2018.
- [cL12] cea Leti. UTSOI Model 1.1.3 Surface Potential Model for Ultra Thin FullyDepleted SOI MOSFET - Model Description. Technical report, cea Leti, 2012.
- [CWLH15] Yen-Lung Chen, Wei Wu, Chien-Nan Jimmy Liu, and Lei He. Incremental Latin hypercube sampling for lifetime stochastic behavioral modeling of analog circuits. In *The 20th Asia and South Pacific Design Automation Conference*, pages 556–561. IEEE, 2015.
- [DGS02] Walter Daems, Georges Gielen, and Willy Sansen. An efficient optimization-based technique to generate posynomial performance models for analog integrated circuits. In *Proceedings of the 39th annual Design Automation Conference*, pages 431–436, 2002.
- [DGS03] Walter Daems, Georges Gielen, and Willy Sansen. Simulation-based generation of posynomial performance models for the sizing of analog integrated circuits. *Computer-Aided Design of Integrated Circuits and Systems, IEEE Transactions on*, 22(5):517–534, 2003.
- [DLR77] Arthur P Dempster, Nan M Laird, and Donald B Rubin. Maximum likelihood from incomplete data via the EM algorithm. *Journal of the royal statistical society: series B (methodological)*, 39(1):1–22, 1977.
- [DMGLGR16] Arnaud De Myttenaere, Boris Golden, Bénédicte Le Grand, and Fabrice Rossi. Mean absolute percentage error for regression models. *Neurocomputing*, 192:38–48, 2016.
- [EKD⁺03] Dan Ernst, Nam Sung Kim, Shidhartha Das, Sanjay Pant, Rajeev Rao, Toan Pham, Conrad Ziesler, David Blaauw, Todd Austin, Krisztian Flautner, et al.

-
- Razor: A low-power pipeline based on circuit-level timing speculation. In *Proceedings. 36th Annual IEEE/ACM International Symposium on Microarchitecture, 2003. MICRO-36.*, pages 7–18. IEEE, 2003.
- [EM13] Georges Gielen Elie Mariceau. *Analog IC Reliability in Nanometer CMOS*. Springer, 2013.
- [EV06] Christian C Enz and Eric A Vittoz. Charge-based MOS transistor modeling. *John Wiley & Sons Inc*, 68, 2006.
- [FYV⁺15] Farshad Firouzi, Fangming Ye, Arunkumar Vijayan, Abhishek Koneru, Krishnendu Chakrabarty, and Mehdi B Tahoori. Re-using BIST for circuit aging monitoring. In *2015 20th IEEE European Test Symposium (ETS)*, pages 1–2. IEEE, 2015.
- [GGP15] Athanasios Gerokostopoulos, Huairui Guo, and Edward Pohl. Determining the right sample size for your test: Theory and application. In *2015 Annual Reliability and Maintainability Symposium Tutorial Notes*, 2015.
- [GLG21] Martin Grabmann, Christian Landrock, and Georg Glaeser. Machine Learning in Charge: Automated Behavioral Modeling of Charge Pump Circuits. In *SMACD/PRIME 2021; International Conference on SMACD and 16th Conference on PRIME*, pages 1–4. VDE, 2021.
- [GM13] Georges Gielen and Elie Maricau. Stochastic degradation modeling and simulation for analog integrated circuits in nanometer CMOS. In *2013 Design, Automation & Test in Europe Conference & Exhibition (DATE)*, pages 326–331. IEEE, 2013.
- [Gra13] Tibor Grasser. *Bias temperature instability for devices and circuits*. Springer Science & Business Media, 2013.
- [Gra14] Tibor Grasser. *Hot carrier degradation in semiconductor devices*. Springer, 2014.
- [GYH11] Fang Gong, Hao Yu, and Lei He. Stochastic analog circuit behavior modeling by point estimation method. In *Proceedings of the 2011 international symposium on Physical design*, pages 175–182, 2011.
- [HAN98] MILITARY HANDBOOK. ELECTRONIC RELIABILITY DESIGN HANDBOOK. Technical report, MIL-HDBK-338B, 1998.
- [Hay02] Simon Haykin. *Adaptive filter theory*. Prentice Hall, Upper Saddle River, NJ, 4th edition, 2002.
- [Hei15] Nils Heidmann. *Alterungsanalyse integrierter CMOS-Schaltungen für den Einsatz in einem Messsystem zur Aufnahmeneuronaler Signale*. PhD thesis, Universität Bremen, 2015.

- [Hei19] Sascha Heinßen. *Entwurf und Implementierung von digitalen Fehlerkorrekturverfahren für Mixed-Signal-Frontend-Schaltungen*. PhD thesis, Universität Bremen, 2019.
- [HHT⁺18a] Sascha Heinssen, Theodor Hillebrand, Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. On-Line Error Correction in Sensor Interface Circuits by Using Adaptive Filtering and Digital Calibration. In *Multidisciplinary Digital Publishing Institute Proceedings*, volume 2, page 963, 2018.
- [HHT⁺18b] Sascha Heinssen, Theodor Hillebrand, Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. On-line monitoring and error correction in sensor interface circuits using digital calibration techniques. In *2018 IEEE 36th VLSI Test Symposium (VTS)*, pages 1–6. IEEE, 2018.
- [Hil18] Theodor Hillebrand. *Alterungsanalyse komplexer analogerintegrierter Schaltungen aus Systemsicht*. PhD thesis, Universität Bremen, 2018.
- [Hof09] K. Hoffmann. *Systemintegration: Vom Transistor zur großintegrierten Schaltung*. De Gruyter, 2009.
- [HPPD18] Theodor Hillebrand, Steffen Paul, and Dagmar Peters-Drolshagen. REL-MOS—A Reliability-Aware MOS Transistor Model. *IEEE Transactions on Electron Devices*, 66(1):60–65, 2018.
- [HS96] Ramesh Harjani and Jianfeng Shao. Feasibility and performance region modeling of analog and digital circuits. In *Modeling and Simulation of Mixed Analog-Digital Systems*, pages 23–43. Springer, 1996.
- [HS16] Jürgen Hedderich and Lothar Sachs. *Angewandte Statistik : Methodensammlung mit R*. Springer Spektrum, Berlin, 2016.
- [ITT⁺17] Mitsuhiko Igarashi, Yoshio Takazawa, Yasumasa Tsukamoto, Kan Takeuchi, and Koji Shibutani. NBTI/PBTI separated BTI monitor with 4.2 x sensitivity by standard cell based unbalanced ring oscillator. In *2017 IEEE Asian Solid-State Circuits Conference (A-SSCC)*, pages 201–204. IEEE, 2017.
- [ITvM07] Ellen Ivers-Tiffée and Waldemar von Münch. *Werkstoffe der Elektrotechnik*. Teubner, 2007.
- [JH17] Jens Lienig and Hans Brümmer. *Fundamentals of electronic systems design*. Electrical Engineering. Springer, Cham, 2017. xiii, 241 Seiten ; 25 cm : Illustrationen, Diagramme.
- [KCG09] Kishore Karnane, G Curtis, and R Goering. Solutions for mixed-signal SoC verification. *Cadence Design Systems*, 2009.
- [KG95] Kenneth S. Kundert and Paul Gray. *The Designer's Guide to Spice and Spectre*. Kluwer Academic Publishers, USA, 1995.

-
- [KG04] Tholom Kiely and Georges Gielen. Performance modeling of analog integrated circuits using least-squares support vector machines. In *Proceedings Design, Automation and Test in Europe Conference and Exhibition*, volume 1, pages 448–453. IEEE, 2004.
- [KKK⁺08] Kelin Kuhn, Chris Kenyon, Avner Kornfeld, Mark Liu, Atul Maheshwari, Weikai Shih, Sam Sivakumar, Greg Taylor, Peter VanDerVoorn, and Keith Zawadzki. Managing Process Variation in Intel’s 45nm CMOS Technology. *Intel Technology Journal*, 12(2), 2008.
- [KWC10] Kyung Ki Kim, Wei Wang, and Ken Choi. On-chip aging sensor circuits for reliable nanometer MOSFET digital circuits. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 57(10):798–802, 2010.
- [KZ04] Kenneth S. Kundert and Olaf Zinke. *The designer’s guide to Verilog-AMS*. The designer’s guide book series. Kluwer Acad. Publ., Boston, Mass. [u.a.], 1. ed. edition, 2004.
- [LJ13] Pong-Fei Lu and Keith A Jenkins. A built-in BTI monitor for long-term data collection in IBM microprocessors. In *2013 IEEE International Reliability Physics Symposium (IRPS)*, pages 4A–1. IEEE, 2013.
- [LSJ⁺15] Andre Lange, Christoph Sohrmann, Roland Jancke, Joachim Haase, Binjie Cheng, Asen Asenov, and Ulf Schlichtmann. Multivariate modeling of variability supporting non-gaussian and correlated parameters. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 35(2):197–210, 2015.
- [LT122] Datenblatt LT1813/LT1814. Technical report, Linear Technology, abgerufen 07.04.2022.
- [LXM⁺18] Huaguo LIANG, FANG Xiangsheng, YI Maoxiang, Zhengfeng Huang, and LU Yingchun. A novel BIST scheme for circuit aging measurement of aerospace chips. *Chinese Journal of Aeronautics*, 31(7):1594–1601, 2018.
- [Mat12] MathWorks. slicesampler MATLAB documentation, Abrufdatum 2021-10-12. <https://de.mathworks.com/help/stats/slicesample.html>.
- [Mat86] Bertil Matérn. *Spatial variation*, volume 36. Springer Science & Business Media, 1986. Originally published by the Swedish National Institute for Forestry Research, 1960.
- [MBC00] Michael D McKay, Richard J Beckman, and William J Conover. A comparison of three methods for selecting values of input variables in the analysis of output from a computer code. *Technometrics*, 42(1):55–61, 2000.
- [MDJG12] Elie Maricau, Dimitri De Jonghe, and Georges Gielen. Hierarchical analog circuit reliability analysis using multivariate nonlinear regression and active

- learning sample selection. In *2012 Design, Automation & Test in Europe Conference & Exhibition (DATE)*, pages 745–750. IEEE, 2012.
- [MG10] Elie Maricau and Georges Gielen. Efficient variability-aware NBTI and hot carrier circuit reliability analysis. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 29(12):1884–1893, 2010.
- [MGTM07] Dale B McDonald, Walter J Grantham, Wayne L Tabor, and Michael J Murphy. Global and local optimization using radial basis function response surface models. *Applied Mathematical Modelling*, 31(10):2095–2110, 2007.
- [MH00] George Moschytz and Markus Hofbauer. Adaptive Filter. *Berlin ua: Springer*, 2000.
- [Mic17] Microelectronics Support Centre STFC Rutherford Appleton Laboratory. *Introduction to Analogue and Mixed Signal IC Design Lecture Notes*, 2017.
- [MJ51] Frank J Massey Jr. The Kolmogorov-Smirnov test for goodness of fit. *Journal of the American statistical Association*, 46(253):68–78, 1951.
- [MLR19] Geoffrey J McLachlan, Sharon X Lee, and Suren I Rathnayake. Finite mixture models. *Annual review of statistics and its application*, 6:355–378, 2019.
- [MM05] Budiman Minasny and Alex. B. McBratney. The Matérn function as a general model for soil variograms. *Geoderma*, 128(3):192–207, 2005. Pedometrics 2003.
- [MMAC16] Raymond H Myers, Douglas C Montgomery, and Christine M Anderson-Cook. *Response surface methodology: process and product optimization using designed experiments*. John Wiley & Sons, 2016.
- [Mon11] Michael Mongillo. Choosing basis functions and shape parameters for radial basis function methods. *SIAM undergraduate research online*, 4(190-209):2–6, 2011.
- [MR05] Ayhan A Mutlu and Mahmud Rahman. Statistical methods for the estimation of process variation effects on circuit operation. *IEEE Transactions on Electronics Packaging Manufacturing*, 28(4):364–375, 2005.
- [MS83] Jorge J Moré and Danny C Sorensen. Computing a trust region step. *SIAM Journal on scientific and statistical computing*, 4(3):553–572, 1983.
- [MS06] Gary S May and Costas J Spanos. *Fundamentals of semiconductor manufacturing and process control*. John Wiley & Sons, 2006.
- [MS16] William M. Mendenhall and Terry L. Sincich. *Statistics for Engineering and the Sciences, Sixth Edition*. Chapman and Hall/CRC, Boca Raton, 6th ed. edition, 2016.
- [Mye10] Albert Myers. *Complex system reliability*. Springer, 2010.

-
- [Nea03] Radford M Neal. Slice sampling. *Annals of statistics*, pages 705–741, 2003.
- [Nel06] Roger B Nelsen. *An introduction to copulas*. Springer, 2006.
- [NP73] Laurence W. Nagel and D.O. Pederson. SPICE (Simulation Program with Integrated Circuit Emphasis). Technical Report UCB/ERL M382, Apr 1973.
- [Raz12] Behzad Razavi. *Design of integrated circuits for optical communications*. John Wiley & Sons, 2012.
- [Ros21] Julian Rosskamp. Implementierung eines Multi-SensorInterfaces zur Bestimmung von Umgebungsparametern in einer 28nm-Technologie. Master’s thesis, Universität Bremen, 2021.
- [Sat16] Ashwin Satyanarayana. Performance modeling of CMOS inverters using support vector machines (SVM) and adaptive sampling. *Microprocessors and Microsystems*, 46:193–201, 2016.
- [SCT⁺21] Davide Severin, Giovanni Capodivacca, Bernard Blaise Tchodjie Tchamabe, Andi Buzo, and Cristian-Vasile Diaconu. Verilog-A model development of a DC–DC boost controller with autonomous optimization. In *SMACD/PRIME 2021; International Conference on SMACD and 16th Conference on PRIME*, pages 1–4. VDE, 2021.
- [SHB08] Ralf Sommer, Thomas Halfmann, and Jochen Broz. Automated behavioral modeling and analytical model-order reduction by application of symbolic circuit analysis for multi-physical systems. *Simulation Modelling Practice and Theory*, 16(8):1024–1039, 2008.
- [SK17] Haralampos-G. Stratigopoulos and Bozena Kaminska. *Electronic design automation for IC system design, verification, and testing*, chapter Analog and Mixed-Signal Test. CRC Press, 2017.
- [SKY⁺18] Mingoo Seok, Peter R. Kinget, Teng Yang, Jiangyi Li, and Doyun Kim. Recent advances in in-situ and in-field aging monitoring and compensation for integrated circuits: Invited paper. In *2018 IEEE International Reliability Physics Symposium (IRPS)*, pages 5C.1–1–5C.1–6, 2018.
- [SN12] Olivier Schwander and Frank Nielsen. Model centroids for the simplification of kernel density estimators. In *Acoustics, Speech and Signal Processing (ICASSP), 2012 IEEE International Conference on*, pages 737–740. IEEE, 2012.
- [Ste99] Michael L Stein. *Interpolation of spatial data: some theory for kriging*. Springer Science & Business Media, 1999.
- [STM23] STMicroelectronics. FD-SOI. https://www.st.com/content/st_com/en/about/innovation---technology/FD-SOI.html, Abrufdatum 01.10.2023.

- [SWK98] Peter A Stolk, Frans P Widdershoven, and DBM Klaassen. Modeling statistical dopant fluctuations in MOS transistors. *IEEE Transactions on Electron devices*, 45(9):1960–1971, 1998.
- [SWV⁺09] Alvin W Strong, Ernest Y Wu, Rolf-Peter Vollertsen, Jordi Sune, Giuseppe La Rosa, Timothy D Sullivan, and Stewart E Rauch III. *Reliability wearout mechanisms in advanced CMOS technologies*, volume 12. John Wiley & Sons, 2009.
- [TLY⁺12] Ming-Chien Tsai, Yi-Wei Lin, Hao-I Yang, Ming-Hsien Tu, Wei-Chiang Shih, Nan-Chun Lien, Kuen-Di Lee, Shyh-Jye Jou, Ching-Te Chuang, and Wei Hwang. Embedded SRAM ring oscillator for in-situ measurement of NBTI and PBTI degradation in CMOS 6T SRAM array. In *Proceedings of Technical Program of 2012 VLSI Design, Automation and Test*, pages 1–4. IEEE, 2012.
- [TRC⁺93] Robert H Tu, Elyse Rosenbaum, Wilson Y Chan, Chester C Li, Eric Minami, Khandker Quader, Ping K Ko, and Chenming Hu. Berkeley reliability tools-BERT. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 12(10):1524–1534, 1993.
- [TS21] Petar Tzenov and Ahmed Sokar. Machine Learning in the Analog Circuit Simulation Loop. In *SMACD/PRIME 2021; International Conference on SMACD and 16th Conference on PRIME*, pages 1–4. VDE, 2021.
- [TSM23] TSMC. 5nm Technology. https://www.tsmc.com/english/dedicatedFoundry/technology/logic/1_5nm, Abrufdatum: 15.06.2023.
- [UC 21] UC Berkeley Device Group. BSIM Group. <http://bsim.berkeley.edu/>, Abrufdatum 07-01-2021.
- [Ver06] Verein Deutscher Ingenieure. *VDI 4001-2: Terminologie der Zuverlässigkeit*. 2006.
- [WKK⁺14] Xiaofei Wang, John Keane, Tony Tae-Hyoung Kim, Pulkit Jain, Qianying Tang, and Chris H Kim. Silicon odometers: Compact in situ aging sensors for robust system design. *IEEE micro*, 34(6):74–85, 2014.
- [WR06] Christopher K Williams and Carl Edward Rasmussen. *Gaussian processes for machine learning*, volume 2. MIT press Cambridge, MA, 2006.

Eigene Publikationen

Die folgenden Listen enthalten die wissenschaftlichen Veröffentlichungen der Autorin. Die Listen sind nach Erstautoren- und Co-Autorenschaft sortiert.

- [1] Maike Taddiken, Nico Hellwege, Nils Heidmann, Dagmar Peters-Drolshagen, and Steffen Paul. Analysis of aging effects-From transistor to system level. *Microelectronics Reliability*, 67:64–73, 2016.
- [2] Maike Taddiken, Theodor Hillebrand, Konstantin Tscherkaschin, Steffen Paul, and Dagmar Peters-Drolshagen. Parameter identification for behavioral modeling of analog components including degradation. In *2016 MIXDES-23rd International Conference Mixed Design of Integrated Circuits and Systems*, pages 336–340. IEEE, 2016.
- [3] Maike Taddiken, Theodor Hillebrand, Steffen Paul, and Dagmar Peters-Drolshagen. Variation-and degradation-aware stochastic behavioral modeling of analog circuit components. In *2017 14th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 1–4. IEEE, 2017.
- [4] Maike Taddiken, Theodor Hillebrand, Steffen Paul, and Dagmar Peters-Drolshagen. LUT-Based Stochastic Modeling for Non-Normal Performance Distributions. In *2018 15th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 1–217. IEEE, 2018.
- [5] Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. ReSeMBleD-Methods for Response Surface Model Behavioral Description. In *2018 15th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 157–160. IEEE, 2018.
- [6] Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. Charge-Based Model for Reliability Analysis Flow of Flip-Flops under Process Variation and Aging. In *2019 16th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 233–236. IEEE, 2019.
- [7] Maike Taddiken, Theodor Hillebrand, Dagmar Peters-Drolshagen, and Steffen Paul. Stochastic behavioral models for system level reliability analysis including non-normal and correlated process variation. *Microelectronics Reliability*, 118:114044, 2021.
- [8] Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. Monitoring Analog Circuit Performance using Adaptive Filters and RSM-based Behavioral Models. In *SMACD/PRIME 2021; International Conference on SMACD and 16th Conference on PRIME*, pages 1–4. VDE, 2021.

-
- [9] Nils Heidmann, Nico Hellwege, Maike Taddiken, Dagmar Peters-Drolshagen, and Steffen Paul. Analog behavioral modeling for age-dependent degradation of complex analog circuits. In *2014 Proceedings of the 21st International Conference Mixed Design of Integrated Circuits and Systems (MIXDES)*, pages 317–322. IEEE, 2014.
- [10] Theodor Hillebrand, Nico Hellwege, Maike Taddiken, Konstantin Tscherkaschin, Steffen Paul, and Dagmar Peters-Drolshagen. Stochastic LUT-based reliability-aware design method for operation point dependent CMOS circuits. In *2016 MIXDES-23rd International Conference Mixed Design of Integrated Circuits and Systems*, pages 363–368. IEEE, 2016.
- [11] Theodor Hillebrand, Maike Taddiken, Konstantin Tscherkaschin, Steffen Paul, and Dagmar Peters-Drolshagen. Online monitoring of NBTI and HCD in beta-multiplier circuits. In *2016 IEEE 22nd International Symposium on On-Line Testing and Robust System Design (IOLTS)*, pages 209–210. IEEE, 2016.
- [12] Theodor Hillebrand, Maike Taddiken, Konstantin Tscherkaschin, Steffen Paul, and Dagmar Peters-Drolshagen. Unified stochastic reliability aware model for SONOS memories in Harsh environments. In *2016 16th European Conference on Radiation and Its Effects on Components and Systems (RADECS)*, pages 1–4. IEEE, 2016.
- [13] Theodor Hillebrand, Maike Taddiken, Konstantin Tscherkaschin, Steffen Paul, and Dagmar Peters-Drolshagen. V_{th} is dead-long live the threshold voltage. In *2016 IEEE International Integrated Reliability Workshop (IIRW)*, pages 61–64. IEEE, 2016.
- [14] Konstantin Tscherkaschin, Theodor Hillebrand, Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. Degradation and temperature analysis of voltage-controlled ring oscillators for robust and reliable oscillator designs in a 65nm bulk CMOS process. In *2016 MIXDES-23rd International Conference Mixed Design of Integrated Circuits and Systems*, pages 353–358. IEEE, 2016.
- [15] Konstantin Tscherkaschin, Theodor Hillebrand, Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. Temperature-and aging-resistant inverter for robust and reliable time to digital circuit designs in a 65nm bulk CMOS process. In *2016 IEEE 22nd International Symposium on On-Line Testing and Robust System Design (IOLTS)*, pages 121–125. IEEE, 2016.
- [16] Sascha Heinssen, Maike Taddiken, Theodor Hillebrand, Steffen Paul, and Dagmar Peters-Drolshagen. Behavioral modeling of a sensor interface circuit including various non-idealities. In *2017 14th International Conference on Synthesis, Modeling, Analysis and Simulation Methods and Applications to Circuit Design (SMACD)*, pages 1–4. IEEE, 2017.
- [17] Sascha Heinssen, Theodor Hillebrand, Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. On-Line Error Correction in Sensor Interface Circuits by Using Adaptive Filtering and Digital Calibration. In *Multidisciplinary Digital Publishing Institute Proceedings*, volume 2, 2018.

- [18] Sascha Heinssen, Theodor Hillebrand, Maike Taddiken, Steffen Paul, and Dagmar Peters-Drolshagen. On-line monitoring and error correction in sensor interface circuits using digital calibration techniques. In *2018 IEEE 36th VLSI Test Symposium (VTS)*, pages 1–6. IEEE, 2018.
- [19] Sascha Heinssen, Theodor Hillebrand, Maike Taddiken, Konstantin Tscherkaschin, Steffen Paul, and Dagmar Peters-Drolshagen. Design for reliability of generic sensor interface circuits. *Microelectronics Reliability*, 80:184–197, 2018.

Präsentationen

- [20] Maike Taddiken, Theodor Hillebrand, Steffen Paul, and Dagmar Peters-Drolshagen. Chasing tails: Reliability-Aware Feasibility Analysis for Analog System Design. In *55th Design Automation Conference (DAC), Work in Progress Poster Session*, 2018.

