

Energieforschungsprogramm

Publizierbarer Endbericht

Programmsteuerung:

Klima- und Energiefonds

Programmabwicklung:

Österreichische Forschungsförderungsgesellschaft mbH (FFG)

Endbericht

erstellt am

18.12.2020

Projekttitlel:

Lichtbogendetektion in DC-Netzen

Regelungsorientierte Identifikation mit Compressed Sensing und symbolischer Klassifikation

FlashCheck

Projektnummer: 858823

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Ausschreibung	3. Ausschreibung Energieforschungsprogramm
Projektstart	01/04/2017
Projektende	30/09/2020
Gesamtprojektdauer (in Monaten)	42 Monate
ProjektnehmerIn (Institution)	Fronius International GmbH
AnsprechpartnerIn	Philipp Rechberger
Postadresse	Günter Fronius Straße 1, 4600 Thalheim b. Wels
Telefon	+43 664 88635266
Fax	
E-mail	rechberger.philipp@fronius.com
Website	www.fronius.com

FlashCheck

Lichtbogendetektion in DC-Netzen – regelungsorientierte Identifikation mit Compressed Sensing und symbolischer Klassifikation

AutorInnen:

Fronius International

Bernd Hofer
Pfeil Reimar
Philipp Rechberger

EATON

Michael Bartonek
Michael Koch
Hartwig Plach

FH OÖ F&E

Gernot Grabmair
Florian Holzinger
Michael Kommenda
Simon Mayr
Peter Zeller

RISC Software

Wolfgang Fenz
Bruno Lindorfer
Stefan Thumfart

1 Inhaltsverzeichnis

1	Inhaltsverzeichnis	4
2	Einleitung	6
2.1	Stand der Technik / Stand des Wissens	6
2.1.1	Lichtbogendetektion	6
2.1.2	Regelungsorientierte Systemmodellierung und modellbasierte Simulation und Identifikation 8	
2.1.3	Symbolische Regression und Klassifikation	9
2.1.4	Compressed Sensing	10
2.2	Ergebnisse aus anderen Projekten	12
2.2.1	PV-Lichtbogenerkennung	12
2.2.2	ProtoFrame	12
2.2.3	Smart Factory Lab	12
2.2.4	Bewertung des Brandrisikos in Photovoltaik-Anlagen und Erstellung von Sicherheitskonzepten zur Risikominimierung	13
3	Inhaltliche Darstellung	13
3.1	Datenerfassung und experimentelle Evaluierung	13
3.1.1	Aufbau und Test des Messsystems	14
3.1.2	Datenaufzeichnung in PV-Systemen	20
3.1.3	Aufbau einer Datenbank	20
3.2	Datenaufzeichnung in einem Batteriespeichersystem	21
3.3	Compressed Sensing	22
3.3.1	Verrauschte Signale	24
3.3.2	Der Modulierte Breitbandwandler	25
3.4	Regelungsorientierte Identifikation	27
3.4.1	Konzept der regelungsorientierten Lichtbogendetektion	28
3.4.2	Modellbildung PV-Quelle	28
3.4.3	Parameteridentifikation	30
3.4.4	Lichtbogendetektion (Gütefunktional)	31
3.5	Modellbasierte Identifikation	32
3.5.1	Datenvorverarbeitung	32

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

3.5.2	Klassifikationsalgorithmen	34
4	Ergebnisse und Schlussfolgerungen	35
4.1	Grundlegende Untersuchung der Lichtbogenphysik	35
4.1.1	Motivation.....	35
4.1.2	Vorgehensweise.....	36
4.1.3	Messergebnisse	37
4.1.4	Zusammenfassung der Resultate.....	37
4.2	Compressed Sensing	39
4.2.1	Test-Signale	40
4.2.2	Simulierte Lichtbogensignale.....	40
4.2.3	Gemessene Lichtbogensignale	41
4.2.4	Lichtbogenerkennung.....	45
4.3	Regelungsorientierte Identifikation	47
4.3.1	Messergebnisse	47
4.3.2	Zusammenfassung und Schlussfolgerungen	50
4.4	Modellbasierte Identifikation	51
4.4.1	Klassifikationsergebnisse für Batteriespeichersysteme	54
5	Ausblick und Empfehlungen.....	56
5.1	Datenerfassung.....	56
5.2	Compressed Sensing	56
5.3	Modellbasierte Identifikation	57
5.4	Klassifikationsalgorithmik	57
5.5	Erkennung in Batteriespeichersystemen	58
6	Literaturverzeichnis.....	59
6.1	Referenzen.....	59
6.1.1	Compressed Sensing.....	59
6.1.2	Modellbasierte Identifikation	62
6.2	Online.....	64
7	Kontaktdaten.....	65

2 Einleitung

Störlichtbögen stellen in Photovoltaikanlagen und Batteriespeichersystemen (Hybridsystemen) aufgrund der großen Gleichspannung und -ströme ein potentiell Sicherheitsrisiko dar. Dies gilt besonders für serielle Lichtbögen, deren Auftreten zumeist durch defekte Kabel oder schlechte elektrische Verbindungen (Alterungseffekte, Umwelteinflüsse oder Tierverschleiß) verursacht wird. Die Folge daraus ist Brandgefahr für umliegende Teile aufgrund der hohen Temperatur dieser massiven Energieentladung.

Die zunehmende Anzahl an installierten Systemen und das Altern der Systemkomponenten samt der Verkabelung werden bei zu erwartendem exponentiell wachsendem Fehlerrisiko in Zukunft vermehrt zu Lichtbogenbildung und dadurch zu Bränden in derartigen Gleichstrom (DC) Mikronetzen führen.

Der Markt bietet heute unterschiedliche Systeme zur Lichtbogendetektion in Photovoltaikanlagen an. Diese Schutzsysteme sind sehr spezifische Lösungen, die speziell für bestimmte Komponenten wie beispielsweise Wechselrichter einiger weniger großer Hersteller optimiert worden sind. Grundsätzlich sind aber alle derzeit verfügbaren Schutzgeräte nur für eingeschränkte Anwendungsfälle konzipiert (beispielsweise Erkennung der normativ geforderten Störlichtbögen). Eine generelle Lösung zur Lichtbogendetektion in DC-Mikronetzen (z.B. Hybridsysteme mit Photovoltaik (PV) Modulen und Batteriespeichern) gibt es derzeit nicht.

Da zurzeit kein allgemeingültiges Konzept für die Störlichtbogendetektion in Hybridsystemen existiert, soll in diesem Projekt die Abhängigkeit der Störlichtbogenereignisse von der Wechselrichterelektronik, verschiedenen Batterielösungen zum Zwischenspeichern der elektrischen Energie und von anderen Störeinflüssen wie etwa der Länge und Leitungsführung der elektrischen Kabel untersucht und modelliert werden. Als Ergebnis werden eine Beschreibung der gemeinsamen Charakteristika von Störlichtbögen in unterschiedlichen Systemkonfigurationen und ein generelles Konzept zur Erkennung von Störlichtbögen angestrebt.

Dazu soll die Quelle-Lastabhängigkeit der Störlichtbogensignale in Abhängigkeit von verschiedenen Systemkonfigurationen erforscht und simulationstechnisch modelliert werden, um Störlichtbogensignale synthetisch generieren zu können. Die regelungsorientierten Systemmodelle werden die Grundlage für neuartige systemidentifikations- bzw. fehlerdiagnosebasierte Methoden zur Lichtbogendetektion liefern.

Weiters wird die Sensorik für die optimale Erfassung der breitbandigen sporadischen Lichtbogensignale erstmals mittels Compressed Sensing untersucht. Darauf aufbauend wollen wir neue Algorithmen zur symbolischen Klassifizierung von dünnbesetzten Lichtbogensignalen ableiten, die eine sehr hohe Detektionsrate von >99% erreichen.

Ein solches zuverlässiges und allgemeingültiges Konzept zur Störlichtbogenerkennung leistet einen wesentlichen Beitrag zur Sicherheit von DC-Mikronetzen.

2.1 Stand der Technik / Stand des Wissens

2.1.1 Lichtbogendetektion

Einer der wesentlichen Nachteile von Gleichstrom (DC) Systemen ist, dass an Kontaktübergängen, welche nicht fest verbunden sind (z.B.: schlecht befestigte Klemmstellen, fehlerhafte Löt- und

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Schweißverbindungen), Lichtbögen entstehen können. Diese wiederum führen zum Abbrand der Kontaktstellen.

Auf Grund der hohen Energie in Batteriespeicher- und PV-Systemen, kann es in weiterer Folge auch zu großflächigeren Bränden kommen (Schlumberger, 2006) (Vaaßen, 2007) (Ji, 2009) (Brooks, 2011). (Siehe Abbildung 1)



Abbildung 1: Beispiele zu real auftretenden Lichtbögen (links: Aufschmelzen einer schadhafte Kontaktstelle direkt im PV Modul, mitte und rechts: Brand am Stranganschlusskasten).

Es gibt bereits seit einigen Jahren Bestrebungen, getrieben aus dem PV Markt, DC-Lichtbögen zu detektieren und entsprechend abzuschalten (Haeberlin, 2010).

Die USA stellen sich dabei als Vorreiter dar, und fordern bereits normativ eine Erkennung und Abschaltung von Lichtbögen zumindest in der seriellen Verkabelung (UL1699B, 2011) (NEC, 2011).

Neben Fronius bieten auch andere Hersteller dazu bereits Forschungsergebnisse bzw. Lösungen an. Zu erwähnen sind zum Beispiel E-T-A (Strobl & Meckler, 2010), Texas Instruments (Boico, 2011) oder Eaton (Luebke, Pier, Pahl, & Breig, 2011).


Dabei wird mittels Signalanalyse auf den DC-Leitungen das Auftreten eines Lichtbogens in der seriellen Verkabelung erkannt und der Wechselrichter entsprechend abgeschaltet.

Auf Grund der Komplexität der Materie sind die verfügbaren Systeme im Wesentlichen dafür geeignet, die Vorschriften in einem normativ spezifizierten Testaufbau zu erfüllen. Die Erkennung von realen Lichtbögen ist jedoch ungleich komplexer und vor allem vielfältiger und lässt sich nicht mit einfachen Schwellwertdetektoren realisieren. Neben der Vielzahl an unterschiedlichen Ausprägungen von Lichtbögen ist auch die Gesamtverkabelung des PV-Generators (Serien- und Parallelschaltung von Modulen sowie die verwendeten Modultechnologien) und eines Batteriesystems mit dem Wechselrichter bei der Analyse zu berücksichtigen (Johnson, et al., 2011).

In realen Systemen ist des Weiteren die Unterscheidung zwischen Lichtbögen und eingekoppelten Störeinflüssen auf die jeweiligen Leitungen notwendig (Johnson, et al., 2011). Obwohl die richtige Erkennung von Lichtbögen sicherheitstechnisch die weitaus größere Relevanz hat, kann auch durch das fälschliche Melden von vermeintlichen Störsignalen ein erheblicher finanzieller Schaden verursacht werden (Stillstand der Anlage, zeitintensive Fehlersuche in der Verkabelung) (Johnson, Oberhauser, Montoya, Fresquez, Gonzalez, & Patel, 2012).

Ein weiterer Aspekt in der Detektion von Lichtbögen ist die Erkennung und vor allem die Unterscheidung von seriellen und parallelen Lichtbögen (Johnson, et al., 2012) (Abbildung 2)

Allgemeines über Lichtbögen



Serieller Lichtbogen

/ Kontaktproblem: Schlechte Kontakte, Leitungsbruch, Korrosion

Paralleler Lichtbogen

/ Isolationsproblem: Alterung, Vibration, Überspannung,

Abbildung 2: Schematische Darstellung von Lichtbögen in der Photovoltaik.

Die Problematik dabei ist, dass das Löschen des Lichtbogens bei den beiden Varianten grundlegend anders erfolgen muss. Bei seriellen Lichtbögen ist der Stromfluss zu unterbrechen. Parallele Lichtbögen können hingegen nur durch Kurzschließen des Generators gelöscht werden. Wird die falsche Reaktion gesetzt, kommt es demnach sogar zu einer Verstärkung des Lichtbogens und einer Erhöhung des Brandrisikos.

Zur Lichtbogenerkennung in Batteriesystemen sind akustische oder optische Verfahren bekannt (Cattin, 2013) (Dahmani, 2015). Neuerdings wurden auch Verfahren, die auf Strom-/ Spannungssignalanalyse basieren, für den Einsatz in Batteriesystemen in Elektrofahrzeugen betrachtet (Strobl, 2014) (Augeard, 2015). Die Erkennung von Lichtbögen in PV/Batterie-Hybridssystemen abhängig vom Systemzustand (Ladung / Entladung) ist nicht dokumentiert und wird im Rahmen dieses Projekts erforscht.

2.1.2 Regelungsorientierte Systemmodellierung und modellbasierte Simulation und Identifikation

Bisher kommen hauptsächlich signalbasierte Algorithmen zur Anwendung, wobei auf das jeweilige Anlagenverhalten in Form von Grenzwerten in definierten Spektralbereichen eingegangen wird. Zahlreiche Arbeiten weisen auf die Problematik der Auswirkungen der hochdynamischen Regelungen in den Photovoltaikinvertoren auf das gesamte Frequenzspektrum hin (Reil, 2013). Lediglich im Stationärbetrieb lässt sich dieses Inverterverhalten auf spezifische Frequenzbereiche einschränken, siehe bspw. (Johnson, 2012).

Modellbasierte Systemidentifikationsansätze sind nun in der Lage, stark abstrahierte generische Anlagenmodelle unter Berücksichtigung der eingesetzten Invertertopologie und Last- und Quellenersatzmodellen an das konkrete Anlagenverhalten anzupassen. Schaltvorgänge in den Invertoren beeinflussen dabei das Modell nicht mehr negativ, da deren Verhalten weitgehend im Modell enthalten ist.

Diese Ansätze liefern in der Folge die Möglichkeit, zum einen eine generelle Änderung des Anlagenverhaltens zu erkennen und zum anderen liefern sie Informationen, welche Signalanteile für signalbasierte Fehlerdetektion besonders relevant sind.

Beispielhaft seien hier sogenannte sensorlose Regelungsverfahren aus dem Magnetlagerbereich angeführt, bei denen das mitmodellerte Leistungselektronikverhalten mittels online Systemidentifikation zu einer positionssensorlosen Lageregelung führt (Glück, 2011).

Insbesondere im Bereich der Lichtbogenerkennung ist eine derartige Anwendung noch nicht bekannt, da für die Identifikationsansätze die Kombination semiheuristischer Teilmodelle zur Simulation des Lichtbogenverhaltens (siehe symbolische Regression im nächsten Abschnitt) mit der restlichen physikalischen modellbasierten Systembeschreibung herausfordernd ist.

2.1.3 Symbolische Regression und Klassifikation

Ein methodischer Ansatz zur Mustererkennung, auf den in diesem Projekt aufgebaut werden soll, ist der Einsatz von auf symbolischer Regression/Klassifikation aufbauenden Methoden für die Systemidentifikation (Ljung 1999). Symbolische Regression (Koza 1992) ist ein datenbasiertes Modellierungsverfahren, bei dem Regressionsmodelle in Form von mathematischen Ausdrücken (Abbildung 3) erstellt werden. Im Vergleich zu den bisher eingesetzten Methoden erscheint symbolische Regression aufgrund folgender Überlegungen besonders attraktiv. Ein Alleinstellungsmerkmal von symbolischer Regression ist die zeitgleiche Optimierung von Modellstruktur und Modellparametern. Wird symbolische Regression für die Modellierung von Klassifikationsaufgaben eingesetzt, spricht man auch von symbolischer Klassifikation.




Abbildung 3: Symbolisches Regressionsmodell in mathematischer Schreibweise und in der Darstellung als Baum für genetische Programmierung.

Unter Betrachtung einer Vielzahl von möglichen mathematischen Ausdrücken und unterschiedlichen Kombinationen von verwendeten Variablen werden symbolische Regressionsprobleme mittels genetischer Programmierung gelöst (Koza 1992, Keijzer 2003, Poli et al. 2008, Affenzeller et al. 2009). Genetische Programmierung (GP) ist eine universell anwendbare Meta-Heuristik (White et al. 2013) für die automatische Synthese von Computerprogrammen oder (im Falle der Anwendung auf symbolische Regression) Formelbäumen. GP orientiert sich dabei, ähnlich wie genetische Algorithmen (Holland 1975) und Evolutionsstrategien (Schwefel 1975), an evolutionären Prozessen und verwendet evolutionäre

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Konzepte wie Selektion, Kreuzung und Mutation, um neue Lösungen in einem iterativen zyklischen Prozess kontinuierlich zu verbessern. Beim Einsatz von GP für symbolische Regression/Klassifikation werden Modelle (Funktionen) als Baum dargestellt. Ein Beispiel eines solchen Baums und der entsprechenden Funktion ist in Abbildung 3 gezeigt. Durch wiederholte Selektion von Modellen überdurchschnittlicher Qualität und Kombination von Teilbäumen aus diesen Modellen werden sukzessive bessere Modelle generiert. Das Prinzip von Genetischer Programmierung ist in Abbildung 4 dargestellt.

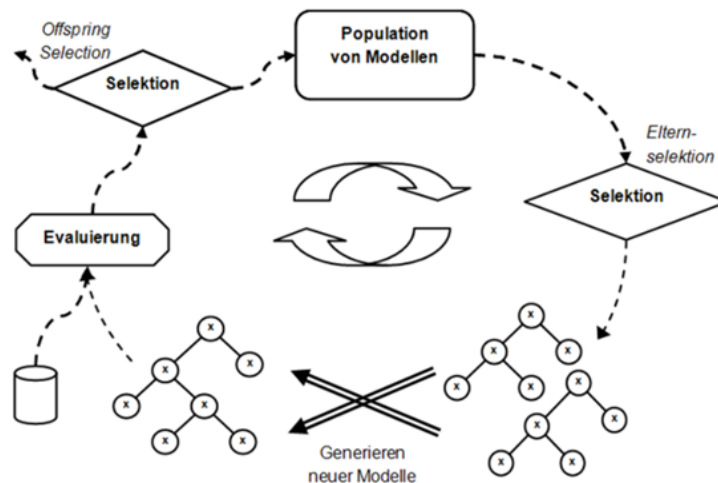


Abbildung 4: Symbolische Regression basierend auf genetischer Programmierung.

In Hinblick auf die Modellierung für Lichtbogenerkennung ist symbolische Regression/Klassifikation besonders attraktiv, da nichtlineare Zusammenhänge - z.B. Polynomfunktionen, rationale Funktionen oder logarithmische, exponentielle bzw. trigonometrische Zusammenhänge - gefunden werden können. Der Algorithmus wählt automatisch die am besten passende Modellstruktur. Gleichzeitig können die erstellten Modelle in Form mathematischer Ausdrücke einfach interpretiert, validiert und transformiert werden (Affenzeller et al. 2014). Zusätzlich ist die Auswertung der Modelle auf neuen Daten effizient und damit die Echtzeitfähigkeit der erstellten Modelle gegeben.

Die Forschungsgruppe HEAL (FH OÖ) hat bereits umfangreiches Know-how in der Anwendung von symbolischer Regression im industriellen Umfeld in diversen Projekten sammeln können und hat sich im akademischen Bereich in Europa als eine der wichtigsten Forschungsgruppen für symbolische Regression etabliert. Mitglieder der Forschungsgruppe haben eine umfangreiche und frei verfügbare Implementierung von symbolischer Regression (Kommenda et al. 2012) in HeuristicLab ([1], Wagner et al., 2014) integriert und veröffentlicht. In HeuristicLab stehen außerdem Standardverfahren für datenbasierte Modellierung wie z.B. Support Vektor Maschinen (Vapnik 1995), Gauß-Prozesse (Rasmussen & Williams 2006), Random Forests (Breiman 2001), Neuronale Netze (Nelles 2001), oder Gradient Boosted Trees (Mason et al. 1999), sowie moderne Weiterentwicklungen von genetischen Algorithmen wie ALPS (Hornby 2006) zur Verfügung. Diese Algorithmen wurden teilweise von Mitgliedern der Forschungsgruppe selbst implementiert, womit auch Know-how für den Einsatz dieser Standardverfahren zur Verfügung steht.

2.1.4 Compressed Sensing

In der klassischen digitalen Signalverarbeitung muss die Abtastrate mindestens doppelt so groß sein wie der höchste Frequenzanteil im Signal. Bei dieser unteren Schranke für die Abtastrate spricht man von der Nyquist-Frequenz. Angewandt auf Lichtbogendetektion, bei der für eine möglichst zuverlässige Erkennung eine breite Frequenzbandabdeckung bis in den MHz-Bereich nötig ist, würde dies eine Abtastrate von

mehreren Millionen Samples pro Sekunde bedeuten. Dies stellt jedoch eine sehr hohe technische Anforderung an die einzusetzenden Messkomponenten dar und erweist sich für den Praxiseinsatz in DC-Mikronetzen als unwirtschaftlich.

Compressed Sensing liefert die theoretischen Grundlagen für neue Signalverarbeitungstechniken, um mit geringeren Abtastraten weit unterhalb der Nyquist-Frequenz breitbandige Signale verarbeiten zu können (Candes, 2006) (Donoho, 2006). Für unterbesetzte (sparse) Signale, welche inkohärent (z.B. pseudozufällig) abgetastet werden, erlaubt Compressed Sensing durch Verwendung von iterativen Rekonstruktionsmethoden eine vollständige Signalbeschreibung.

Eine zentrale Rolle im Compressed Sensing hat die Messmatrix. Das komprimierte gemessene Ausgangssignal ist das Produkt der Messmatrix mit dem Eingangssignal. Die Dimension des Signalraums des gemessenen Signals ist um 1 bis 2 Dekaden niedriger als die Dimension des Eingangssignals, was eine signifikante Reduktion der Samplingrate erlaubt. Die Messmatrix wird dabei analog implementiert. Beispiele finden sich in der Optik - bei der Einpixelkamera werden etwa pseudozufällig angeordnete binäre Masken verwendet, wobei sich eine Reduktion der räumlichen Abtastfrequenz ergibt (Candes 2008).

Für Abtastung sehr breitbandiger Signale mittels Compressed Sensing wurde 2010 von Mishali und Eldar der modulierte Breitbandwandler vorgestellt (Mishali & Eldar, 2010). Bei diesem System wird das analoge Eingangssignal zuerst mit einer Bank von periodischen Signalen multipliziert. Die Produkte werden anschließend gemischt und mit niedriger Rate gleichmäßig abgetastet. Es können damit Signalanteile aus allen Bändern gleichzeitig erfasst werden. Es können dann entweder das Eingangssignal iterativ rekonstruiert werden oder auch direkt Detektionsalgorithmen für das Compressed Sensing-Signal entwickelt werden. Anwendung (Duarte & Eldar, 2011) findet dieses System beispielsweise in Empfängern (Chen, 2011), (Shi, et al., 2008), EEG-Signalerfassung (Mamaghanian, 2011) und adaptiven Analog/Digitalwandler (Trakimas, 2011). Die Erweiterung auf Vorverarbeitung und Signalratenreduktion für Lichtbogenerkennung wird im Rahmen dieses Projekts erstmals erprobt.

Für die Rekonstruktion des ursprünglichen Signals aus der Messung werden unterschiedliche numerische Methoden angewendet: Bei der konvexen Optimierung (Basis Pursuit), z. B. mittels Interior Point Methoden (Candes 2006), Projected Gradient (Figueiredo 2007), oder Iterative Thresholding (Daubechies 2004), werden die wenigsten Messungen benötigt, sie ist jedoch auch mit dem größten Rechenaufwand verbunden. Kombinatorische Algorithmen (z.B. Gilbert 2007) wiederum bieten zwar sublineare Performance, sind allerdings auf eine hohe Zahl von Messpunkten angewiesen. Einen guten Kompromiss bieten die sogenannten Greedy Algorithms, insbesondere Orthogonal Matching Pursuit (Pati 1993) und dessen Erweiterungen. Diese basieren auf iterativer Näherung des dünnbesetzten Koeffizientenvektors und sind schnell und relativ einfach zu implementieren.

In diesem Projekt wurde die Möglichkeit untersucht, Aspekte der CS-Theorie auf die Erkennung von Lichtbögen in Gleichstromsystemen anzuwenden, wobei sowohl simulierte als auch gemessene Lichtbogensignaturen verwendet werden. Die wesentlichen Punkte dabei sind:

- Es wird ein neuartiges Verfahren zur Lichtbogendetektion in PV-Systemen vorgestellt, das Änderungen im HF-Teil (>750 kHz) des aktuellen Signalspektrums erkennt, während eine Sub-Nyquist-Gesamtabtastrate in einer kleinen Anzahl paralleler Kanäle verwendet wird, die jeweils mit 50 kHz abgetastet werden.
- Sie basiert auf der Annahme, dass ein schmaler Frequenzbereich des Spektrums genügend Informationen enthält, um zwischen einem regulären Signal und einem Signal mit einer

Lichtbogensignatur zu unterscheiden. Wir machen uns diese Eigenschaft zunutze, indem wir den entsprechenden Bereich des Spektrums herausfiltern, so dass das resultierende Signal die Dünnbesetztheits-Bedingungen erfüllt, die für die Anwendung von CS-Verfahren, insbesondere des modulierten Breitbandwandlers, erforderlich sind.

- Es wird gezeigt, wie der rechnerische Aufwand des oben genannten Detektionsverfahrens minimiert werden kann, indem man die Tatsache nutzt, dass die Bandposition im Voraus bekannt ist und eine Rekonstruktion des ursprünglichen Signals nicht notwendig ist.
- Es wird gezeigt, wie Methoden aus dem statistischen Lernen, nämlich die Lineare Diskriminanzanalyse, angewendet werden können, um diejenigen Frequenzbänder zu identifizieren, die sich am besten für die Lichtbogendetektion eignen.

2.2 Ergebnisse aus anderen Projekten

2.2.1 PV-Lichtbogenerkennung

(2014 – 2016, FFG-Projekt „Stadt der Zukunft“)

Abgrenzung zum Projekt „Flashcheck“: Das Ziel des Projektes PV-Lichtbogenerkennung liegt in der sicheren und realistischen Erkennung von DC Lichtbögen in *Photovoltaikanlagen im urbanen Bereich*. Im Rahmen von Flashcheck betrachten wir erstmals das Lichtbogenzündverhalten in *Hybridsystemen mit PV und/oder Batterien in unterschiedlichen Betriebsarten* (z.B. Laden und Entladen der Batterie mit und ohne PV im Netzkoppel und Parallelbetrieb).

Synergien: Ein Großteil der Laborinfrastruktur steht bereits zur Verfügung und kann in diesem Projekt mitverwendet werden. Auf dem bestehenden Know-How zum Thema kann aufgebaut werden (Basiswissen rund um Niedervolt / Niederstrom Lichtbögen, Risikobewusstsein, Störeinflüsse auf DC Leitungen, Aufbau Lichtbogengenerator, Toolchain zur Erprobung von Mustererkennungsverfahren).

2.2.2 ProtoFrame

(2013-2016, FFG Coin Aufbau)

Abgrenzung zum Projekt „Flashcheck“: Keinerlei Behandlung von Lichtbögen. Primär mechanische Mehrkörper- bzw. mechatronische Systeme. Keine Fehlerdiagnoseverfahren entwickelt.

Synergien: Einsatz und Adaption der aufgebauten fachlichen Expertise zum weitgehend automatisierten Abgleich von realen und virtuellen Prototypen mechatronischer Systeme. Dies umfasst zum einen die Identifikation von Parametern numerischer Simulationsmodelle auf Basis von Prüfstandergebnissen. Zum anderen werden Verfahren zur optimalen Anregung von Prüfständen entwickelt und implementiert, sodass eine möglichst hohe Signifikanz der zu ermittelnden Parameter gegeben ist. Diese entwickelten Algorithmen sollen für den Einsatz in der Leistungselektronik und insbesondere für die Lichtbogendetektion weiterentwickelt werden.

2.2.3 Smart Factory Lab

(2016-2018, IWB 2020 Projekt)

Gerade in der Anfangsphase befindet sich das IWB 2020 Projekt Smart Factory Lab, in welchem echtzeitfähige Methoden erarbeitet werden, um im Sinne von preemptive und predictive Maintenance aus Datenströmen realer und virtueller Sensordaten adhoc stattfindende oder sich schleichend darstellenden Änderungen des Systemverhaltens identifizieren zu können. Synergien mit dem beantragten Projektvorhaben sollten sich hier in der Weiterentwicklung von sliding windows basierten Modellierungsmethoden und deren Interpretation im Sinne von regime shifts oder regime changes ergeben.

2.2.4 Bewertung des Brandrisikos in Photovoltaik-Anlagen und Erstellung von Sicherheitskonzepten zur Risikominimierung

(2011 – 2014, gefördertes Projekt durch das deutsche Bundesministerium für Umwelt, Naturschutz und Reaktorsicherheit)

Das Forschungsprojekt soll die Teilnehmer dabei unterstützen, die Sicherheit von PV-Systemen in Bezug auf das Lichtbogenrisiko und allgemeine Brandgefahren zu optimieren. Das Konsortium wird gemeinsam von TÜV Rheinland und Fraunhofer Institut für Solare Energiesysteme (ISE) geführt. Innerhalb dieses Forschungsprojektes soll die Sicherheit von PV-Anlagen hinsichtlich Risiken zur Lichtbogenentstehung und deren Gefahren beim Ausbruch eines Brandes mit und ohne Beteiligung der PV-Anlage untersucht werden. Besonderes Augenmerk wird der in der Öffentlichkeit aktuell diskutierten Sicherheit der Feuerwehreinsetzungskräfte beim Gebäudebrand gewidmet (Fraunhofer-Institut für Solare Energiesysteme ISE, 2013).

Abgrenzung zum Projekt „PV-Lichtbogenkennung“: Das beschriebene Projekt befasst sich mit der Sensibilisierung der Marktteilnehmer zur Entwicklung entsprechender Sicherheitseinrichtungen bzw. Komponenten mit integrierten Sicherheitselementen *wohingegen* sich unser Projekt mit der konkreten Erforschung von Erkennungsverfahren und deren signaltheoretischen Grundlagen bei PV Lichtbögen beschäftigt.

3 Inhaltliche Darstellung

3.1 Datenerfassung und experimentelle Evaluierung

Für das Projekt war es maßgeblich eine gemeinsame Datenbasis zu erstellen, um unterschiedliche Algorithmen zur Lichtbogendetektion (LBD) untereinander zu vergleichen. Die Datenbank sollte Aufzeichnungen der Spannung und des Stromes der PV Anlage umfassen. Dafür wurde eine externe Messdatenerfassungseinheit (engl. Arc Measurement Box, AMB) entwickelt, welche einerseits diese Aufzeichnungen gewährleistet und andererseits Algorithmen zur LBD beinhaltet um zielgerecht Lichtbogenereignisse (LBE) aufzeichnen zu können. Das Gerät sollte Ströme bis 50 A und Spannungen bis 1000 V unterstützen und diese mit einer hohen Abtastrate (8 MSps) erfassen (siehe Abbildung 5).

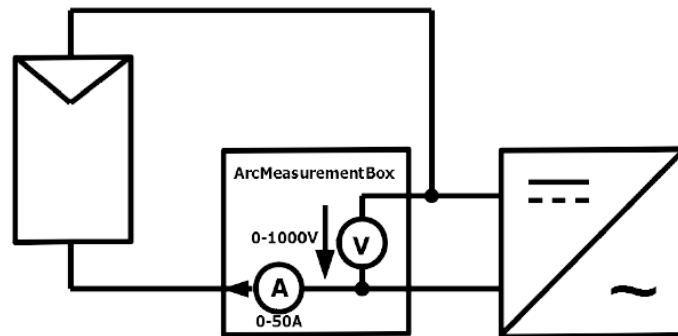


Abbildung 5: Skizze des Messaufbaus. Links: PV Feld, Rechts: Inverter, Mitte: AMB Messeinheit.

3.1.1 Aufbau und Test des Messsystems

Die AMBs sollten dann bei diversen PV Installationen verbaut werden und automatisch LBE aufzeichnen. Deshalb war in der Entwicklung auch besonderer Wert auf die Robustheit gegenüber Umwelteinflüssen und Langlebigkeit gelegt.

Für die Umsetzung der AMB wurde auch kommerziell verfügbare Lösungen von

- Tektronix
- PicoScope
- Dewetron

untersucht. Aufgrund der hohen Anschaffungskosten (Tektronix, Dewetron), deren Ausrichtung auf Labormessungen (PicoScope), der Notwendigkeit von Vorverstärkern bzw. einer zentralen Verarbeitungseinheit (alle) wurde diese Möglichkeit nicht weiter verfolgt.

Stattdessen wurde ein FPGA-basiertes Test- und Messboard namens RedPitaya (siehe Abbildung 6) als Basis verwendet und die Signalkonditionierungshardware eigens entwickelt.




Abbildung 6: Red Pitaya Messboard mit dessen Anschlüssen.

Im fertigen Aufbau (siehe Abbildung 7) wurden zwei RedPitaya Systeme da vier hochfrequente Aufzeichnungskanäle notwendig sind:

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

- PV Strom gemessen mit LEM CKSR50 [6] Sensor (0-100 kHz): $I_{DC,LF}$
- PV Strom gemessen über einem Power Communication Line (PLC) Transformer (20 kHz – 2 MHz): $I_{DC,HF}$
- DC PV Spannung im Bereich zwischen 0 -1000 V mit einer Bandbreite von 0 – 100 kHz: $U_{DC,LF}$
- AC PV Spannung im Bereich zwischen +/- 100 V mit einer Bandbreite von 1 kHz – 2 MHz: $U_{DC,HF}$



Abbildung 7: Finales AMB System mit zwei Red Pitaya Messboards und Signalkonditionierungsplatine.

Obwohl die RedPitaya Messeinrichtungen bis zu 125 MSps unterstützen, wurde die Abtastrate auf 8 MSps beschränkt um die Datenspeicherung für eine längere Zeitdauer gewährleisten zu können.

3.1.1.1 Signalkonditionierungsplatine

Die Messschaltung für die Verstärkung des Messkanals $I_{DC,LF}$ ist in Abbildung 8 dargestellt. Der verwendete LEM CKSR 50 konvertiert den 0-50 A Eingangsstrom auf einen 0-5 V Spannungsbereich. Dieser wird mit der angegebenen Schaltung auf +/- 1 V transformiert. Zusätzlich wird mittels des Operationsverstärkers (OPV) ein 100 kHz Tiefpass zweiter Ordnung realisiert um Aliasing Effekt zu verhindern und ein 430 kHz Störsignal des Sensors zu filtern.

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

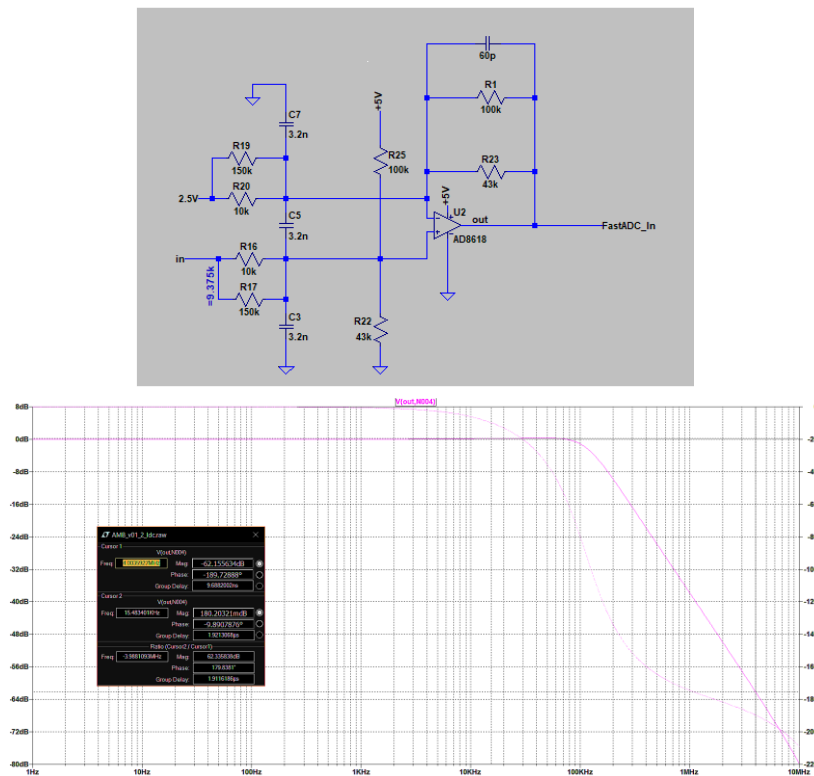


Abbildung 8: Spice Model der Verstärkerschaltung (oben) und Simulation von I_(DC,LF) Kanal

Für den $I_{DC,HF}$ Kanal war eine deutlich komplexe Signalanpassungsschaltung nötig (siehe Abbildung 9). Grund dafür ist der PLC Transformator welcher zusätzlich einen 4 Ohm Shunt Widerstand und eine Tiefpass Filterbegrenzung auf 2 MHz wegen folgender Effekte benötigt:

- Vermeidung von Beschädigung des OPVs durch Stromspitzen
- Filterung von raschen Stromsprüngen und Störungen von der Primärseite

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

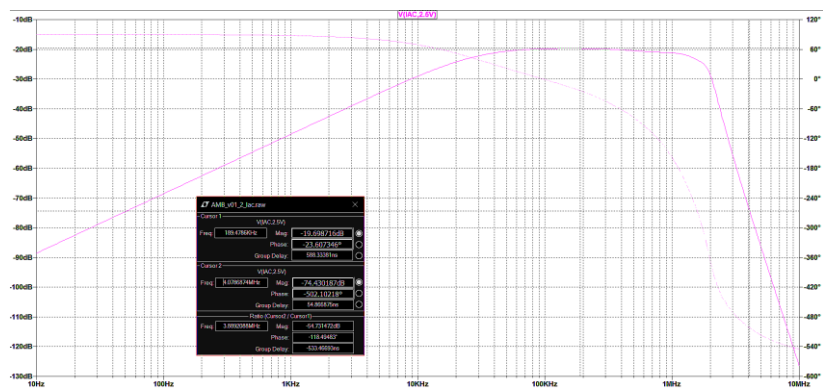
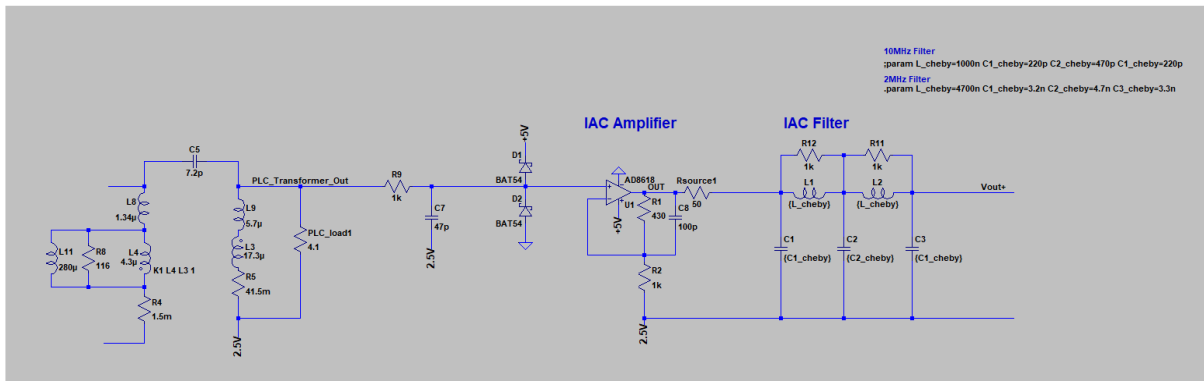


Abbildung 9: Spice Model der Verstärkerschaltung (oben) und Simulation (unten) von I_(DC,HF) Kanal.

Für die Messung der Spannungseingänge $U_{DC,LF}$ und $U_{DC,HF}$ wurden die Schaltungen in Abbildung 10 bzw. Abbildung 11 verwendet. In beiden Schaltungen wurden abgestimmte Messwiderstände verwendet.

Beim $U_{DC,LF}$ Kanal wurden 9 x 1 MOhm Widerstände verwendet um Geichtaktfehler des OPVs zu verringern und ein Sallen Key Tiefpassfilter verwendet um den Messbereich zu begrenzen.

Beim $U_{DC,HF}$ Kanal wurde ein 3 μ F Kondensator in Hochpassschaltung verwendet zur Entfernung von niederfrequenten Spannungsripples und ein Chebyshev Filter 5ter Ordnung zur Einhaltung einer -60 dB Unterdrückung bei 4 MHz (Vermeidung von Aliasing Effekten).




Abbildung 10: Spice Model der Verstärkerschaltung (links) und Simulation (rechts) von U_(DC,LF) Kanal.

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Abbildung 11: Spice Model der Verstärkerschaltung (links) und Simulation (rechts) von U_(DC,HF) Kanal.

3.1.1.2 Programmierung der AMB für LBD

Wie bereits angeführt, war es notwendig LBD Algorithmen direkt in der AMB Systemsoftware zu programmieren, um einen Trigger für etwaige LBEs zu erhalten. Diese Algorithmen mussten im FPGA der entsprechenden AMB Einheit implementiert werden.

Generell, wurde alle LBD Algorithmen möglichst sensitiv ausgelegt, um eine möglichst große Zahl von Messungen zu erreichen. Es war nie der Anspruch an das System, Algorithmen aus PV Wechselrichtern dort zu testen, da die Konvertierung von einem Mikrokontroller-basierten Ansatz auf VHDL zu aufwändig gewesen wäre. Deshalb entsprechen die angeführten Methoden veralteten Ansätzen, deren Anfälligkeit für Fehlauflösungen bewusst in Kauf genommen wurde.

Zunächst kam hier ein Varianzbasierter Ansatz gem. Abbildung 12 zum Einsatz. Man beachte dass der vorgeschlagene Tiefpassfilter Signalanteile $< 400 \text{ kHz}$ entfernt, da darüber Einstreuungen bzw. Resonanzen in der PV Installationen auftreten.

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

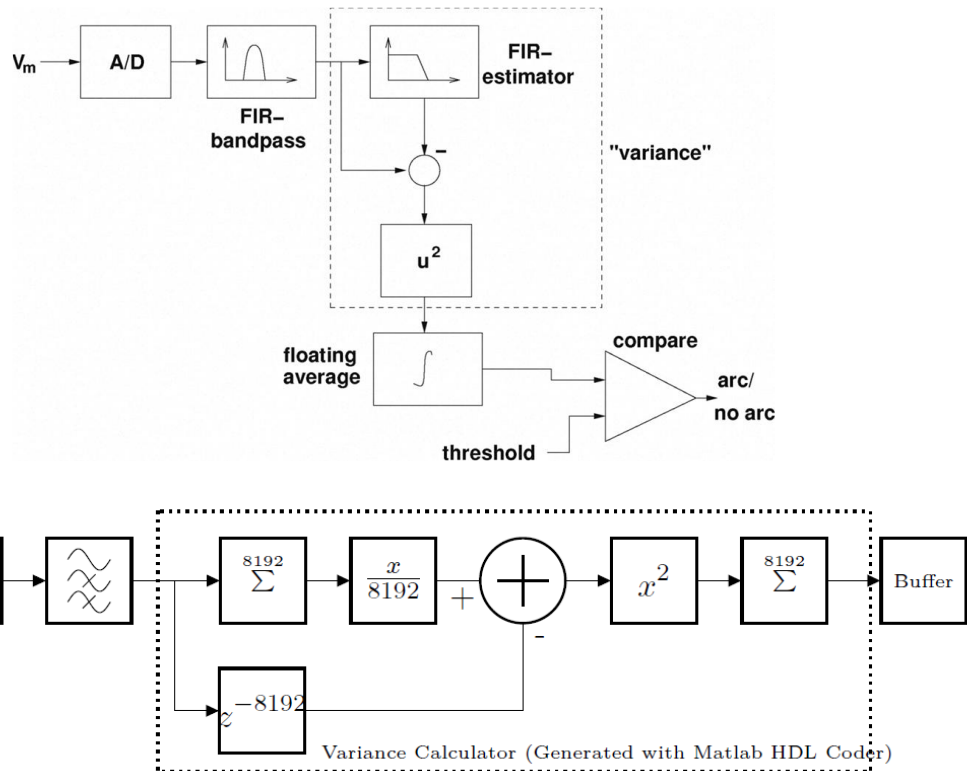


Abbildung 12: Varianzbasierte LBD: Konzept (oben) und Implementierung im FPGA.

Leider erwies sich dieser Ansatz als zu sensibel weshalb eine frequenzbasierte Detektion mit einer FFT-Verarbeitung [7] gem. Abbildung 13 im FPGA implementiert wurde.




Abbildung 13: Implementierung von frequenzbasierter LBD Ansatz im FPGA.

Ein beispielhaftes Ergebnis der Auswertung ist in Abbildung 14 angeführt. Mit diesem Ansatz war es möglich die Anzahl der Fehlalarme erheblich zu begrenzen und gleichzeitig aber noch ausreichend Messdaten von LBE-ähnlichen Ereignissen zu erhalten (vgl. Abbildung 15).

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

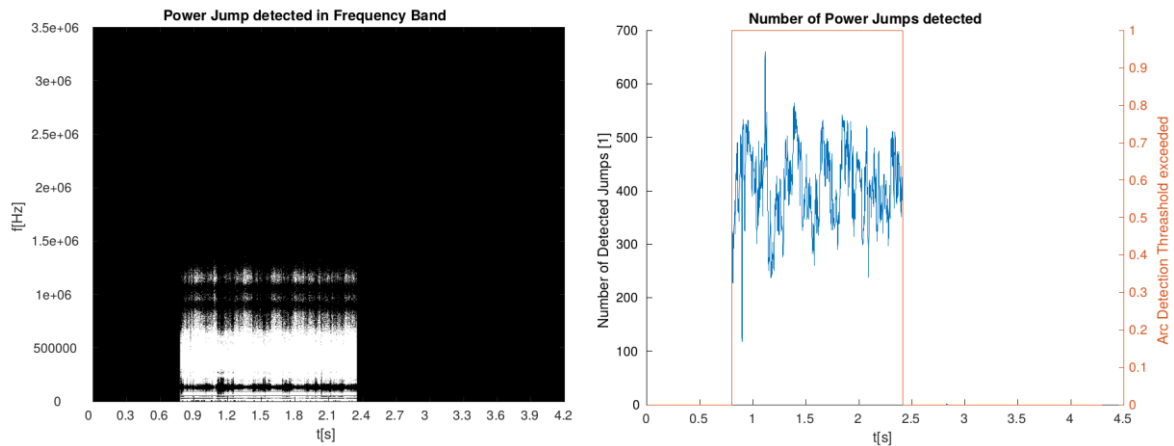


Abbildung 14: Beispielhaftes Ergebnis einer LBD mit frequenzbasierten Ansatz. Rechts: Spectrogram mit Lichtbogensignatur zwischen 0.9 und 2.4 s, Links: Ergebnis der Varianzberechnung und Entscheidung auf Lichtbogen.

3.1.2 Datenaufzeichnung in PV-Systemen

Mit dem vorliegenden System konnten erfolgreich Messdaten während einer LB Messung und vermeintliche LBEs aufgezeichnet werden. Exemplarisch sind zwei Messungen in Abbildung 15 dargestellt.

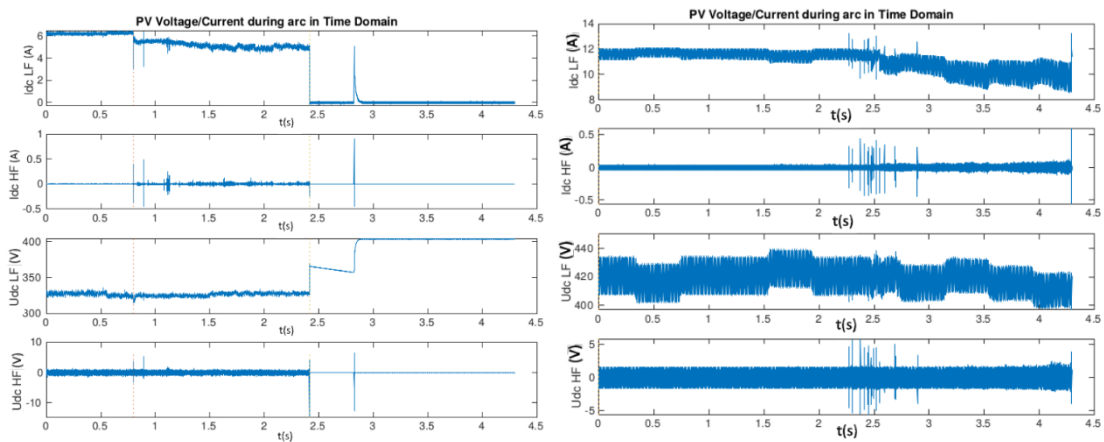


Abbildung 15: Links: Detektion während einer Lichtbogenmessung. Die Zündung beginnt ca. bei 0.7 s und die Auslöschung nach ca. 1.7 s bei 2.4 s. Man beachte, dass nach dem LBE die elektrische Verbindung nicht mehr vorhanden ist, weshalb der Strom (bis auf Schaltspitze bei 2.8 s) bei 0 A liegt. Rechts: Fehlauflösung von Algorithmus bei einer PV-Installation. Aufgrund vom Stromspitzen bei ca. 2.5 s bzw. einem nachfolgenden erhöhten Rauschen kam es zu einer Fehldetektion.

3.1.3 Aufbau einer Datenbank

Leider war der Aufbau einer umfassenden Datenbank nicht erfolgreich, da die Kommunikationsproblematik zwischen AMB und den Server der Aufwand im Datentransfer unterschätzt wurde. Zwar konnten mehrere hundert Messdaten von diversen PV-Systemen erfolgreich erfasst werden, nur leider wurde kein automatischer Transfer von AMB zum einem Server-System implementiert, weshalb diese manuell (d.h. über eine Secure Shell Verbindung direkt zum AMB) übertragen werden mussten. Da

ein Messdatensatz bereits über eine Größe von 256 MB verfügte, waren die vor Ort verfügbaren 32 GB Speicher rasch ausgeschöpft. Dazu dauerte die Übertragung trotz 100 MBs LAN Verbindung mehrere Stunden, welches durch häufige Verbindungsabbrüche noch verschärft wurde.

3.2 Datenaufzeichnung in einem Batteriespeichersystem

Die Ergebnisse aus der Lichtbogendetektion in PV-Systemen wurden an einem Batteriesystemaufbau an der FH Wels evaluiert. Dazu wurde ein Batteriespeichersystem (siehe Abbildung 16) bestehend aus 264 einzelnen Speicherzellen Panasonic NCR-18650PF mit jeweils eigenem Batteriemanagementsystem für je 11 Zellen in Serie konzipiert und aufgebaut. Die maximal mögliche Spannung beträgt 1108 V bei einem Strom von 6 A.

Über eine rein ohmsche Last soll die Batterie zwischen beweglichen Elektroden einen Lichtbogen treiben, den der an PV-Systemlichtbögen trainierte Klassifikator detektieren soll. Obwohl im hier beschriebenen Anwendungsfall der Lichtbogen auch mit einem einfachen Schwellwertoperator zuverlässig detektiert werden kann, soll dieser Versuch zeigen, inwieweit der komplexe und leistungsfähige Klassifikator generalisierbar ist.

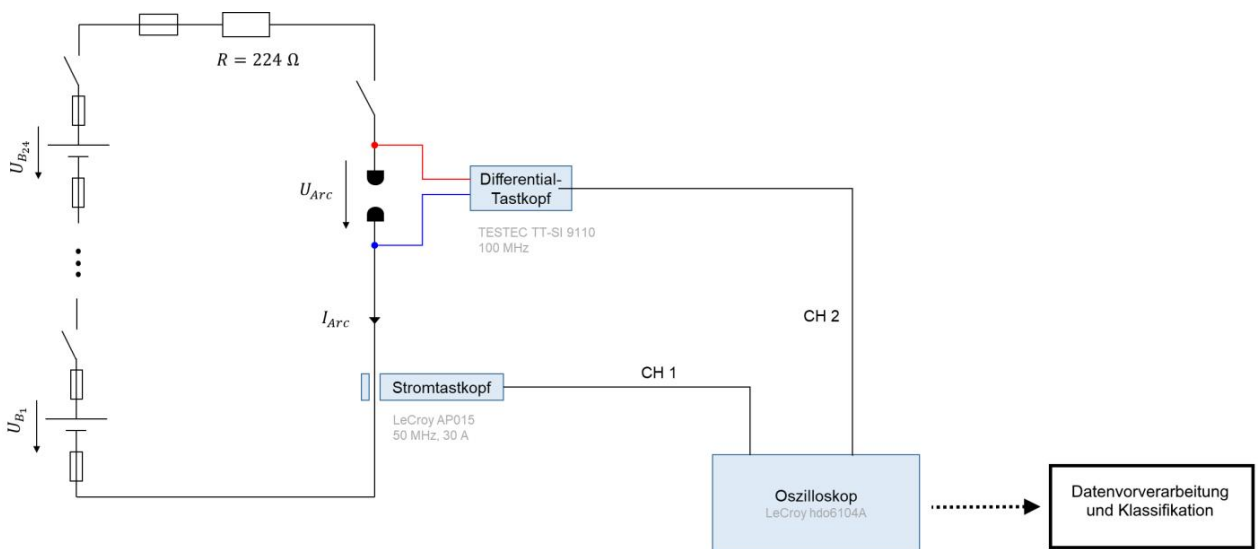


Abbildung 16: Das Lichtbogendetektionssystem, das an der FH Wels mit einem Batteriespeichersystem als Energiequelle aufgebaut wurde, misst die Lichtbogenspannung U_{Arc} und den Lichtbogenstrom I_{Arc} über Spannungs- und Stromsensoren mit Hilfe eines hochauflösenden Oszil

Ein typischer Lichtbogenverlauf bei 500V Batteriespannung und einem Strom von 7,7A ist in Abbildung 17 zu sehen. Die Zündung erfolgt auf der Zeitachse bei etwa -0,24 Sekunden. Ab hier zeigt das Lichtbogenspannungssignal einen Sprung, da der Spannungsabfall an den Elektroden zuvor annähernd null war und durch das Auseinanderfahren der Elektroden aufgrund des entstehenden Lichtbogens abrupt anwächst.

Dieser einfache Anwendungsfall führt zu einem Lichtbogenspannungs- und stromverlauf, die durch keine anderen Störfaktoren wie beispielsweise Überlagerungen von Wechselrichter-störsignalen wesentlich beeinflusst werden. Als nahezu unverfälscht ideale Lichtbogensignatur weist es alle typischen

Charakteristiken eines Lichtbogensignals auf, sodass eine eindeutige Detektion mit einem universell gültigen Lichtbogenklassifikator zu erwarten ist.

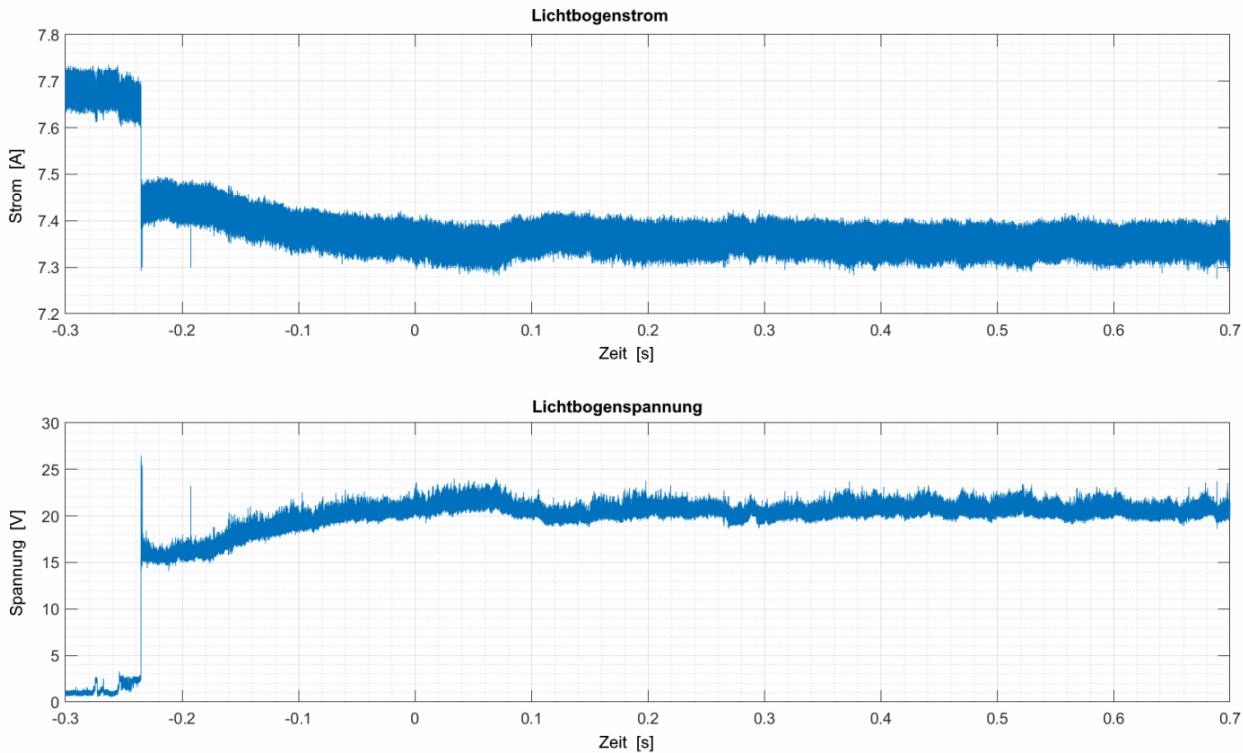


Abbildung 17: Ein Beispiel eines erzeugten Lichtbogens getrieben aus dem Batteriespeicher, bei dem die Lichtbogenspannung und der Strom aufgezeichnet wurden. Die Zündung des Lichtbogens bei etwa -0,24 Sekunden führt zu einem signifikanten Anstieg der Lichtbogenspannung.

3.3 Compressed Sensing

In der klassischen Signalverarbeitung besagt das bekannte Nyquist-Kriterium, dass eine Funktion $x(t)$ mit der höchstfrequenten Komponente f_{\max} perfekt rekonstruiert werden kann, wenn die Abtastfrequenz f_s die Ungleichung $f_s > 2f_{\max}$ erfüllt. Die Untergrenze $2f_{\max}$ wird oft auch als *Nyquist-Frequenz* f_{NYQ} bezeichnet. Bei Anwendungen mit HF-Signalen, die Frequenzanteile im Megahertz-Bereich enthalten, weist das Nyquist-Kriterium auf die Notwendigkeit eines Analog-Digital-Wandlers (ADC) hin, der in der Lage ist, Millionen von Abtastwerten pro Sekunde zu erfassen. Solche ADCs gibt es zwar, aber sie können unerschwinglich teuer sein und schlecht funktionieren, wenn sie an die Grenze ihrer Abtastfähigkeiten gebracht werden. Infolgedessen ist eines der Ziele der modernen Signalverarbeitungstheorie die Entwicklung von Techniken, mit denen Signale rekonstruiert werden können, die mit einer Abtastrate unterhalb der Nyquist-Frequenz f_{NYQ} gesampelt werden. Im CS liegt der Schwerpunkt darauf, die Dünnesetztheit eines Signals zu nutzen, um mit einer viel geringeren Rate abzutasten, als das Nyquist-Kriterium erlauben würde.

Sei $\mathbf{x} \in \mathbb{R}^n$ ein diskreter Signalvektor der Länge n . Der Träger S von \mathbf{x} ist definiert als die Menge seiner Nicht-Null-Einträge,

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

$$S = \{i | x_i \neq 0\}. \tag{1}$$

\mathbf{x} heißt *s-dünnbesetzt* (*s-sparse*) wenn sein Träger die Mächtigkeit $s \ll n$ hat, i. e.

$$s = |S| \equiv \|\mathbf{x}\|_0, \tag{2}$$

was identisch mit der Pseudo-Norm ℓ_0 von \mathbf{x} ist. Wenn wir $m < n$ lineare Messungen von \mathbf{x} vornehmen, erhalten wir einen *komprimierten* Vektor $\mathbf{y} \in \mathbb{R}^m$,

$$\mathbf{y} = \mathbf{A}\mathbf{x}, \tag{3}$$

wobei $\mathbf{A} \in \mathbb{R}^{m \times n}$ die sogenannte *Compressed Sensing* or *Mess-Matrix* ist. Wenn \mathbf{x} *s-sparse* ist und $m \geq s$, kann das ursprüngliche Signal immer noch aus \mathbf{y} rekonstruiert werden, vorausgesetzt, dass die Matrix \mathbf{A} bestimmte Bedingungen erfüllt, wie z.B. die Eigenschaft der eingeschränkten Isometrie (*Restricted Isometry Property*, RIP [30]) bzw. die *mutual incoherence property* (MIP) [34]. Es lässt sich zeigen, dass viele Arten von Zufallsmatrizen wie Gauß-Matrizen und zufällige Fourier-Matrizen diese Bedingungen mit hoher Wahrscheinlichkeit erfüllen. Der naheliegendste Weg, \mathbf{x} zu erhalten, wäre das Lösen des kombinatorischen Optimierungsproblems

$$\hat{\mathbf{x}} = \operatorname{argmin} \|\mathbf{x}\|_0 \quad \text{s. t. } \mathbf{A}\mathbf{x} = \mathbf{y}, \tag{4}$$

was den spärlichsten Vektor $\hat{\mathbf{x}}$ ergibt, der (3) erfüllt. Es stellt sich jedoch heraus, dass die Lösung von (4) im Allgemeinen NP-schwer [35] ist und dass in der Praxis andere Alternativen erforderlich sind. Ein möglicher Ansatz ist die konvexe Relaxation von (4), auch bekannt als *Basis Pursuit* [36], welche die ℓ_1 - statt der ℓ_0 -Norm minimiert,

$$\hat{\mathbf{x}} = \operatorname{argmin} \|\mathbf{x}\|_1 \quad \text{s. t. } \mathbf{A}\mathbf{x} = \mathbf{y}, \tag{5}$$

wobei $\|\mathbf{x}\|_1 = \sum_{i=1}^n |x_i|$. Unter der Voraussetzung, dass \mathbf{A} die RIP erfüllt, stellt die Lösung des Optimierungsproblems (5) das ursprüngliche dünnbesetzte Signal wieder her.

Alternativ gibt es auch so genannte „gierige“ Algorithmen, wie *Matching Pursuit* (MP) [37] and *Orthogonal Matching Pursuit* (OMP) [38, 39], die sich dem Lösungsvektor iterativ annähern und oft vorzuziehen sind, da sie weniger rechenintensiv sind. Die Gleichung (3) wird auch als *single measurement vector* (SMV)-Problem bezeichnet. Eine natürliche Erweiterung von (3) ist durch das *multiple measurement vector* (MMV)-Problem gegeben. Angenommen, wir nehmen d Messungen vor,

$$\mathbf{y}^{(k)} = \mathbf{A}\mathbf{x}^{(k)}, \quad k = 1, \dots, d, \tag{6}$$

wobei die d Vektoren $\mathbf{x}^{(k)}$ *zusammen s-sparse* sind, d.h. sie sind jeweils *s-sparse* und haben an den gleichen Stellen Einträge ungleich Null. Das MMV kann dann geschrieben werden als

$$\mathbf{Y} = \mathbf{A}\mathbf{X}, \tag{7}$$

wobei $\mathbf{Y} = [\mathbf{y}^{(1)}, \mathbf{y}^{(2)}, \dots, \mathbf{y}^{(d)}]$ eine $m \times d$ Matrix ist und \mathbf{X} eine $n \times d$ Matrix die *zeilenweise dünnbesetzt* ist (nur s Zeilen haben Einträge ungleich Null). Die Rekonstruktion von \mathbf{X} aus \mathbf{Y} läuft nun darauf hinaus, das Optimierungsproblem

$$\hat{\mathbf{X}} = \operatorname{argmin} |S(\mathbf{X})| \quad \text{s. t. } \mathbf{A}\mathbf{X} = \mathbf{Y}, \tag{8}$$

zu lösen, wobei $|S(\mathbf{X})|$ die Anzahl der Zeilen in \mathbf{X} mit Einträgen ungleich null ist. Die Lösung von (8) ist wiederum NP-schwer und muss durch geeignete Erweiterungen von gierigen SMV-Lösungsalgorithmen [40] approximiert werden. Ein anderer Weg zur Lösung von (8) ist über den Reduce-and-Boost Algorithmus [41], der die MMV auf eine Reihe von SMV-Problemen reduziert, indem die Spalten von \mathbf{Y} zufällig zu einem einzigen Vektor aufaddiert werden und der erhaltene SMV-Träger zur Konstruktion der Matrix $\hat{\mathbf{X}}$ verwendet wird.

Schließlich kann (7) auf ein Kontinuum von Vektoren $\mathbf{y}(\lambda)$ erweitert werden, für die gilt

$$\mathbf{y}(\lambda) = \mathbf{A}\mathbf{x}(\lambda), \quad \lambda \in \Lambda, \tag{9}$$

wobei Λ eine unendliche Menge ist. Für eine *zusammen dünnbesetzte* Vektormenge $\mathbf{x}(\lambda)$ wird (9) als *infinite measurement vector* (IMV) Problem bezeichnet. In [41] stellen Mishali und Eldar eine Methode zur Lösung des IMV-Problems vor, indem sie es auf ein MMV-System reduzieren.

Konkret zeigen sie, dass, wenn $\mathbf{V} \in \mathbb{R}^{m \times p}$ ein Frame für $\mathbf{y}(\lambda)$ ist, die Lösung $\hat{\mathbf{U}}$ des MMV-Problems

$$\mathbf{V} = \mathbf{A}\mathbf{U} \tag{10}$$

den gleichen Träger hat wie die Lösung $\hat{\mathbf{x}}(\lambda)$ von (9). Eine Möglichkeit, die Matrix \mathbf{V} zu konstruieren, besteht in einer Zerlegung der $m \times m$ Matrix

$$\mathbf{Q} = \int_{\lambda \in \Lambda} \mathbf{y}(\lambda)\mathbf{y}^H(\lambda)d\lambda \tag{11}$$

in

$$\mathbf{Q} = \mathbf{V}\mathbf{V}^H. \tag{12}$$

Sobald man den Trägers S von $\hat{\mathbf{x}}(\lambda)$ kennt, können seine Nicht-Null-Einträge $\hat{\mathbf{x}}_S(\lambda)$ als

$$\hat{\mathbf{x}}_S(\lambda) = \mathbf{A}_S^+ \mathbf{y}(\lambda), \tag{13}$$

ermittelt werden, wobei \mathbf{A}_S^+ die Moore-Penrose-Pseudoinverse der Submatrix \mathbf{A}_S ist, die aus den von S indizierten Spalten von \mathbf{A} besteht. Im Folgenden zeigen wir, wie diese Ergebnisse verwendet werden können, um kontinuierliche analoge Breitbandsignale zu rekonstruieren, deren Frequenzspektrum ebenfalls auf gewisse Weise dünnbesetzt ist.

3.3.1 Verrauschte Signale

Die Definition der Dünnbesetztheit (2) ist für reale Signale nicht gut geeignet: Selbst, wenn die Mehrzahl der Einträge im Signalvektor \mathbf{x} sehr klein ist, wird keiner exakt Null sein, da immer etwas Rauschen vorhanden ist. In diesem Fall ist jedoch $\|\mathbf{x}\|_0$ immer gleich der Signallänge n , und daher ist es vorzuziehen, ein anderes Maß für die Dünnbesetztheit zu finden, das die Anzahl der "großen" Koordinaten von \mathbf{x} misst. In Anlehnung an Lopes [42] definieren wir die *numerische Dünnbesetztheit* $s(\mathbf{x})$ als

$$s(\mathbf{x}) \equiv \frac{\|\mathbf{x}\|_1^2}{\|\mathbf{x}\|_2^2} \leq \|\mathbf{x}\|_0. \tag{14}$$

In der Praxis, insbesondere bei großen Signallängen, ist es besser, diese Zahl durch n zu dividieren,

$$\bar{s}(\mathbf{x}) \equiv \frac{s(\mathbf{x})}{n}, \tag{15}$$

was ein von der Signallänge unabhängiges Maß für Dünnbesetztheit ergibt, die sogenannte *reduzierte numerische Dünnbesetztheit* $\bar{s}(\mathbf{x})$. Ein Wert von $\bar{s}(\mathbf{x}) = 0.1$ bedeutet zum Beispiel, dass 10% der Einträge in \mathbf{x} groß sind, während der Rest klein ist.

3.3.2 Der Modulierte Breitbandwandler

Mishali und Eldar [31] führten den *Modulierten Breitbandwandler (Modulated Wideband Converter, MWC)* ein, um ein Sub-Nyquist-Sampling von analogen Mehrbandsignalen durchzuführen, deren Frequenzträger nur einen kleinen Teil eines breiten Spektrums einnimmt. Man betrachtet als Eingangssignal $x(t)$ ein Mehrbandsignal mit der Fourier-Transformation $X(f)$, deren Träger in N disjunkten Intervallen (Bändern) im Frequenzbereich $\mathcal{F} = [-T/2, T/2]$ enthalten ist, wobei $T = 1/f_{\text{NYQ}}$ der Kehrwert der Nyquist-Rate ist, und keine der einzelnen Bandbreiten größer ist als B . Die Zahl der Bänder inkludiert hierbei auch die symmetrisch konjugierten Bänder mit negativen Frequenzen, ist also die doppelte Anzahl der realen Bänder N_0 . Wenn nun so ein Signal weniger als die Hälfte des Nyquist-Bereichs belegt ($NB < f_{\text{NYQ}}/2$), lässt sich zeigen, dass die minimale notwendige Abtastrate für perfekte Rekonstruktion bei nicht bekannten Bandpositionen $2NB$ beträgt [43]. Je kleiner also der belegte Anteil des Signalträgers (je "dünnbesetzter" das Signal), desto kleiner ist die für eine perfekte Rekonstruktion erforderliche Abtastrate.




Abbildung 18: Links: Schematische Darstellung des Modulated Wideband Converter. Rechts: Beispiel einer Mischfunktion $p_i(t)$ (aus [31]).




Abbildung 19: Links: Fourier-Transformation $X(f)$ des Signals $x(t)$ mit Spektralabschnitten der Breite f_p . Rechts: Der Vektor $\mathbf{z}(f)$ aus (18) für $L = 11$ (aus [31]).

Abbildung 18 zeigt den schematischen Aufbau des MWC. Das Signal $x(t)$ wird zunächst mit einer Bank aus m periodischen Mischfunktionen $p_i(t)$ mit Frequenz f_p multipliziert. Im einfachsten Fall besteht jede Periode T_p von p_i aus M Intervallen, in denen p_i jeweils konstant und entweder -1 oder $+1$ ist. Jedes gemischte Signal wird anschließend mit der Grenzfrequenz $1/(2T_s)$ tiefpaßgefiltert und der Frequenz $f_s = 1/T_s$ abgetastet. Um die Abtastrate zu minimieren, sollten die Frequenzen als $f_s = f_p = B$ gewählt werden. Jeder Kanalausgang $y_i[n]$ ergibt dann eine Mischung aus allen von Null verschiedenen Spektralabschnitten von $X(f)$ mit der Breite f_p , verschoben in das Basisband $\mathcal{F}_s = [-f_s/2, +f_s/2]$, (vgl. Abbildung 19). Im Frequenzbereich wird dies durch die Gleichung

$$\mathbf{y}(f) = \mathbf{A}\mathbf{z}(f), \quad f \in \mathcal{F}_s, \tag{16}$$

dargestellt. Dabei ist $\mathbf{y}(f)$ ein Vektor der Länge m , dessen i -tes Element

$$y_i(f) = \sum_{n=-\infty}^{\infty} y_i[n] e^{-2\pi jfnT_s} \tag{17}$$

die zeitdiskrete Fourier-Transformation (DTFT) von $y_i[n]$ ist. Jeder Eintrag des Vektors $\mathbf{z}(f) = [z_1(f), \dots, z_L(f)]^T$ stellt ein Frequenzband von $X(f)$ mit der Breite f_p dar, das um ein ganzzahliges Vielfaches von f_p verschoben ist, d.h.

$$z_i(f) = X(f + (i - L_0 - 1)f_p), \quad 1 \leq i \leq L, \quad f \in \mathcal{F}_s, \tag{18}$$

wobei $L = 2L_0 + 1$ die minimal nötige Anzahl solcher Spektralabschnitte ist, um den Frequenzbereich \mathcal{F} des Signals abzudecken. Solange $f_p \geq B$ ist, trägt jedes Band des Signals bei einer bestimmten Frequenz f nur ein Nicht-Null-Element zu $\mathbf{z}(f)$ bei, weshalb $\mathbf{z}(f)$ ein dünnbesetzter Vektor mit höchstens $N < L$ Elementen ungleich Null ist.

Nun hat (16) offensichtlich die gleiche Form wie (9) und bildet ein IMV-System mit der $m \times L$ CS-Matrix \mathbf{A} . Die Matrix \mathbf{A} enthält die Vorzeichenabfolgen, die in den Mischfunktionen $p_i(t)$ auftreten, und man kann zeigen, dass sie die RIP erfüllt, wenn die Vorzeichen zufällig gewählt werden. Um das ursprüngliche Signal wiederherzustellen, muss die am dünnsten besetzte Lösung $\hat{\mathbf{z}}(f)$ von (16) gefunden werden, indem das

MMV-Problem (10) gelöst wird. Hat man $\hat{\mathbf{z}}(f)$ ermittelt, so kann das rekonstruierte Signal $\hat{x}(t)$ aus der inversen DTFT $\hat{\mathbf{z}}[n]$ mittels digitaler Filterung und Modulation [31] berechnet werden.

Genau wie beim SMV-Problem (3) entspricht die Anzahl der Kanäle m der Anzahl der zufälligen Messungen des dünnbesetzten Analogsignals $x(t)$. Daher gilt: je größer m , desto höher die Wahrscheinlichkeit, das ursprüngliche Signal erfolgreich wiederherzustellen. Andererseits beeinflusst die Anzahl der Kanäle direkt die Gesamtabtastrate des Systems, mf_s , weshalb ein kleinerer Wert von m natürlich im Hinblick auf Hardwarekosten und Systemgröße vorteilhaft ist. Laut dem ersten Absatz dieses Abschnitts muss m für perfekte Blindrekonstruktion mindestens $2N$ betragen. Unter Verwendung der RIP-Eigenschaft der Matrix \mathbf{A} zeigen Mishali und Eldar, dass $x(t)$ mit hoher Wahrscheinlichkeit rekonstruiert werden kann, wenn m zumindest

$$m_{\min} \approx 4N \log(M/2N) \tag{19}$$

beträgt. Da M immer auf seinen Mindestwert gesetzt werden kann, der für $f_s = f_p$ identisch mit $M_{\min} = L$ ist, hängt die für eine stabile Rekonstruktion erforderliche Anzahl von Kanälen somit nur von der Anzahl der Nicht-Null-Bänder im Signal ab.

Darüber hinaus zeigten Mishali und Eldar auch eine Möglichkeit auf, die Anzahl der Kanäle auf Kosten einer höheren Abtastrate pro Kanal ($f_s = qf_p$, wobei q eine ungerade Zahl ist) und zusätzlicher digitaler Rechenschritte zu verringern.




Abbildung 20: Links: Positives Frequenzspektrum $X(f)$ eines Test-Breitbandsignals $x(t)$ mit einem SNR von 20 dB und dessen Rekonstruktion $\tilde{X}(f)$ mit unserer MWC-Implementierung. Der MWC stellt das originale (unverrauschte) dünnbesetzte Signal wieder her, weshalb die Spektren außerhalb der Rechteck-Peaks sich nicht überlappen. Rechts: Erfolgsrate für die Rekonstruktion unsere Testsignale als Funktion der Anzahl von Kanälen m für verschiedene SNR-Werte.

3.4 Regelungsorientierte Identifikation

Üblicherweise besteht eine Photovoltaik-Anlage (PV-Anlage) aus den folgenden relevanten Bestandteilen:

- PV-Paneele (PV-Quelle),
- Verkabelung,
- Inverter (EMV-Filter, DC/DC Konverter, Zwischenkreis, Wechselrichter).

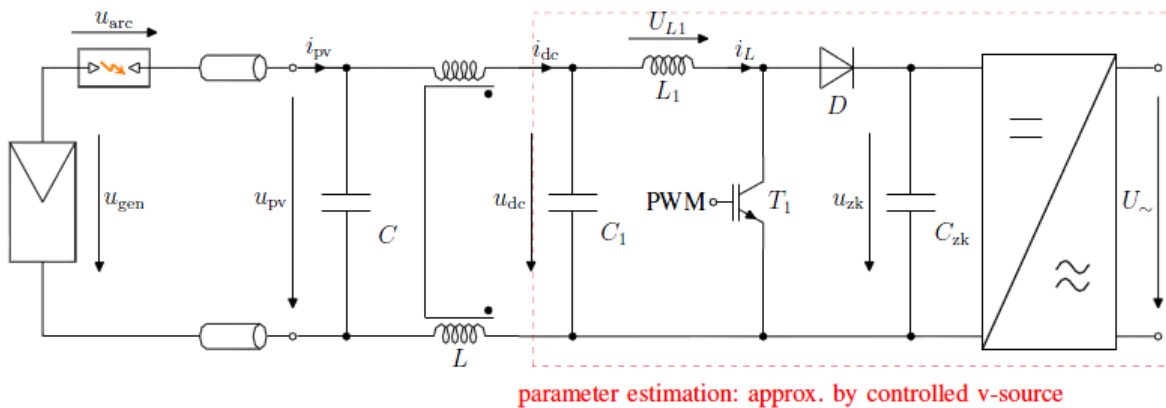


Abbildung 21: Schematisches Übersichtsdiagramm der untersuchten PV-Anlage

Weitere Baugruppen, wie Schutzbeschaltung, Grid-Optimizer, etc. werden in diesen Untersuchungen nicht betrachtet. Außerdem beschränken wir uns für die Messkampagnen auf 1-phasige Wechselrichter.

Im Inverter wird Spannung und Strom in der Eingangsstufe nach dem EMV-Filter gemessen. Die zur Verfügung stehenden Signale für die Lichtbogendetektion sind u_{DC} und i_{DC} .

3.4.1 Konzept der regelungsorientierten Lichtbogendetektion

Im Unterschied zu den meisten am Markt erhältlichen Lichtbogendetektoren verfolgt die in diesem Projekt entwickelte Methode zur Störlichtbogendetektion keinen direkten Ansatz, d.h. es wird nicht der Störlichtbogen selbst identifiziert und detektiert. Es wird das „normale“ Betriebsverhalten der PV-Quelle prädiziert, wobei „erlaubte“ Änderungen im Verhalten, verursacht durch, z.B. Abschattung, Temperatur, etc. permanent durch Adaptierung der entsprechenden Modellparameter berücksichtigt werden. Abweichungen vom zu erwarteten Anlagenverhalten sind ein Indikator für Fehlerfälle, bspw. verursacht durch Störlichtbögen. Für die Unterscheidung zwischen „zulässigen“ und „unzulässigen“ Änderungen wird der Faktor Zeit herangezogen. Es ist anzunehmen, dass Störlichtbögen wesentlich schneller auftreten, als Änderungen der Umwelteinflüsse (Einstrahlung, Verschattung, Wolken, etc.). Die entwickelte Methode kann in drei Schritte unterteilt werden:

- Online Parameterschätzung der unbekannt Parameter des PV-Modells
- Finden eines geeigneten Gütefunktional (Kriterium) welches auf den Parameterschätzwerten basiert, und für die Lichtbogendetektion geeignet ist
- Vergleich des Gütefunktional mit einem Schwellwert zur Detektion von Lichtbögen

Wichtig zu erwähnen ist, dass die präsentierte Methode einen allgemeineren Fehlerdetektor darstellt, und nicht nur bei Störlichtbögen auslöst.

3.4.2 Modellbildung PV-Quelle

Die PV-Quelle wird als einfache Ersatzspannungsquelle, bestehend aus einer Spannungsquelle U_0 und einem ohmschen Widerstand R_0 , modelliert. Diese lineare (tangente) Approximation der nichtlinearen Charakteristik von PV-Paneele durch ein lineares Modell ist natürlich nur in einem sehr kleinen Umfeld

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

um den aktuellen Arbeitspunkt gültig, siehe Abbildung 22. Um Arbeitspunktänderungen folgen zu können, werden die Modellparameter U_0 , R_0 permanent geschätzt und das Modell damit ständig nachparametriert.

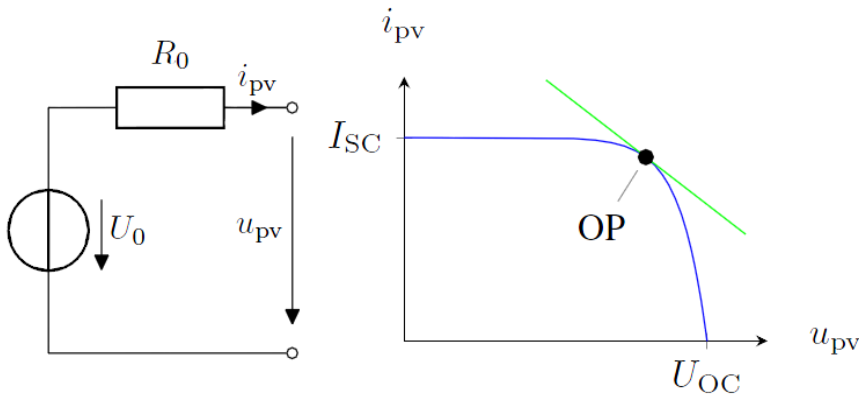


Abbildung 22: Statisches PV-Ersatzmodell mit linearer (tangentialer) Approximation der nichtlinearen PV-Charakteristik im Arbeitspunkt (OP)

Basierend auf der schematischen Darstellung der PV-Anlage aus Abbildung 21 und den zur Verfügung stehenden Messgrößen (u_{DC} , i_{DC}), erhalten wir ein relativ einfaches elektrisches Ersatzschaltbild. Die PV-Quelle wird durch das statische Ersatzmodell approximiert, während der verbleibende Teil des Inverters (DC/DC-Wandler, Zwischenkreis und Netzeinflüsse) durch eine geregelte Spannungsquelle abgebildet wird.




Abbildung 23: Elektrische Ersatzschaltung bestehend aus PV-Modell (unbekannte Parameter) und dem bekannten EMV-Filter.

Für die Modellgleichungen erhalten wir

$$\begin{pmatrix} \dot{i}_{pv} \\ \dot{i}_{dc} \end{pmatrix} = \begin{pmatrix} -\frac{1}{R_0 C} u_{pv} - \frac{1}{C} i_{dc} + \frac{U_0}{R_0 C} \\ \frac{1}{L} u_{pv} - \frac{R}{L} i_{dc} \end{pmatrix} + \begin{pmatrix} 0 \\ -\frac{1}{L} \end{pmatrix} u_{dc} \quad (20)$$

$$\mathbf{y} = (u_{pv} \quad i_{dc})^T$$

mit dem Zustandsvektor $\mathbf{x} = (u_{pv}, i_{dc})^T$, den unbekanntem PV-Modell Parametern $\mathbf{p}_{PV} = (U_0, R_0)^T$, und den bekannten EMV-Filter Parametern $\mathbf{p}_{EMV} = (R, L, C)^T$.

3.4.3 Parameteridentifikation

Bevor die eigentliche Parameteridentifikation der PV-Ersatzparameter durchgeführt wird, muss sichergestellt werden, dass diese in der vorhandenen Schaltungskonfiguration prinzipiell strukturell identifizierbar sind. Eine solche Identifizierbarkeitsanalyse basiert auf der (lokalen) Beobachtbarkeitsanalyse von nichtlinearen Systemen. Dabei werden die zu interessierenden Parameter als zusätzliche konstante Systemzustände interpretiert und die Beobachtbarkeit überprüft. Detailliertere Ausführungen sind in der im Rahmen des Projekts entstandenen Publikation [Mayr, 2019] enthalten. In [Mayr, 2019] wird gezeigt, dass die Identifizierbarkeit der unbekannt Parameter nur für den Fall einer konstanten Leistungsentnahme $P_{load} = u_{DC} i_{DC}$ verloren geht. Einphasige Wechselrichter geben die Leistung bauartbedingt mit einer Oszillation der doppelten Netzfrequenz an das Netz ab, was in diesem Fall die Identifizierbarkeit garantiert. Bei dreiphasigen Wechselrichtern muss also für die Identifizierbarkeit eine leichte Schwankung des Arbeitspunktes garantiert werden, was in der Praxis durch MPP-Tracker, sich ändernde Umwelteinflüsse, etc. der Fall sein sollte.

In der Praxis ist damit die Identifizierbarkeit gewährleistet.

Die Parameterschätzung kann in zwei Phasen unterteilt werden. Einerseits müssen die zeitlichen Ableitungen der Signale in (20) bestimmt bzw. eliminiert, und andererseits das Gleichungssystem gelöst werden. Zur Eliminierung der zeitlichen Ableitungen wird die sogenannte Poisson-Moment-Functional (PMF) Methode verwendet. Diese kann als Filterung der Signale mit den Impulsantworten entsprechender Filter interpretiert werden. Für die Lösung des überbestimmten algebraischen Gleichungssystems verwenden wir den bekannten Least-Squares Ansatz. Großer Vorteil der gewählten Methode ist die Möglichkeit der rekursiven Implementierung, d.h. der Algorithmus ist online-fähig, und dessen geringer Ressourcenbedarf.

Wir erhalten ein algebraisches Gleichungssystem der Form

$$y_{LSQ}(t_k) = y_{LSQ}(k) = \mathbf{w}^T(t_k) \mathbf{p}_{pv} \tag{21}$$

$$\begin{aligned} \mathbf{w}^T &= (-1 * g_{f_0}, i_{dc} * g_{f_0} + C(u_{dc} * g_{f_1} + Ri_{dc} * g_{f_1} \\ &\quad + L(\alpha_0 i_{dc} - \alpha_1 i_{dc} * g_{f_1} - \alpha_0 i_{dc} * g_{f_0}))) \\ y_{LSQ} &= -Ri_{dc} * g_{f_0} - Li_{dc} * g_{f_1} - u_{dc} * g_{f_0} \\ \mathbf{p}_{pv} &= (U_0, R_0)^T \end{aligned} \tag{22}$$

mit den entsprechenden Impulsantworten bzw. Filtern

$$\begin{aligned} g_{f_0} &= \mathcal{L}^{-1}\{F_0(s)\}, \quad g_{f_1} = \mathcal{L}^{-1}\{F_1(s)\} \\ F_0(s) &= \frac{\alpha_0}{s^2 + \alpha_1 s + \alpha_0}, \quad F_1(s) = sF_0(s) \end{aligned} \tag{23}$$

Das Gleichungssystem wird an $N > 2$ diskreten Zeitpunkten t_k ausgewertet und die Schätzwerte der unbekanntem Modellparameter mittels Least-Squares bestimmt. Der rekursive Least-Squares Algorithmus mit exponentiellem Vergessen ergibt

$$\begin{aligned} \Phi(k) &= \frac{\mathbf{P}(k-1) \mathbf{w}(k)}{\lambda + \mathbf{w}^T(k) \mathbf{P}(k-1) \mathbf{w}(k)} \\ \mathbf{P}(k) &= \frac{1}{\lambda} (\mathbf{P}(k-1) - \Phi(k) \mathbf{w}^T(k) \mathbf{P}(k-1)) \\ \hat{\mathbf{p}}_{pv}(k) &= \hat{\mathbf{p}}_{pv}(k-1) \\ &\quad + \Phi(k) (y_{LSQ}(k) - \mathbf{w}^T(k) \hat{\mathbf{p}}_{pv}(k-1)) \end{aligned} \tag{24}$$

Das exponentielle Vergessen ermöglicht dem Algorithmus Änderungen im Arbeitspunkt der PV-Kennlinie zu folgen und das Modell permanent neu zu parametrieren. Ein solcher Arbeitspunktwechsel ist in Abbildung 24 dargestellt.

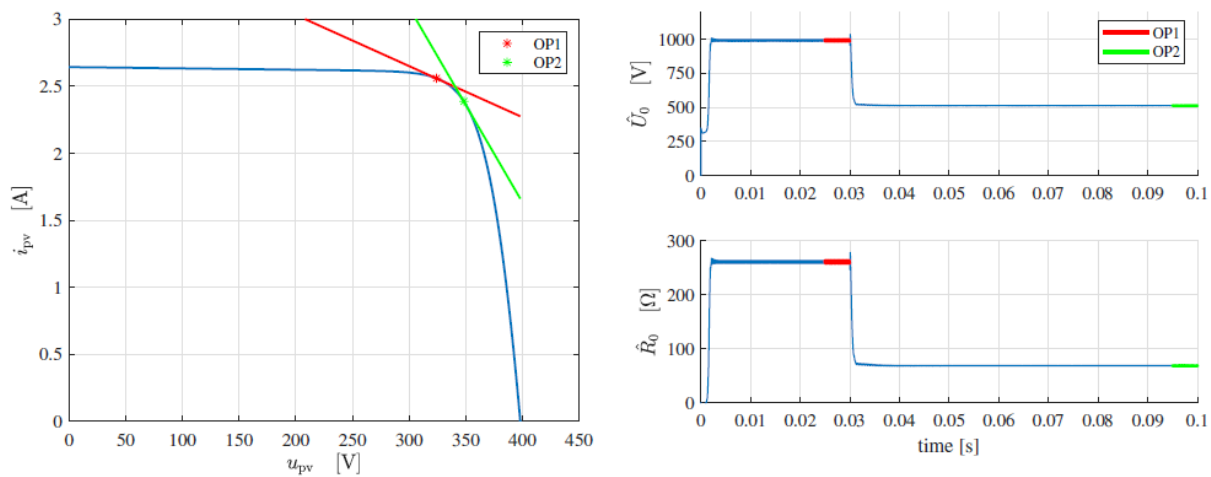


Abbildung 24: Arbeitspunktwechsel

3.4.4 Lichtbogendetektion (Gütefunktional)

Basierend auf den geschätzten Modellparametern werden unterschiedliche Gütefunktionale bzw. Kriterien auf die Eignung zur Lichtbogendetektion untersucht. Naheliegender ist es die Schätzwerte selbst bzw. Änderungsraten der geschätzten Parameterwerte als Gütefunktional zu verwenden. Der Lichtbogen ist im PV-Ersatzmodell nicht abgebildet, und resultiert in ungültigen bzw. stark schwankenden Schätzwerten. Weitere Kandidaten sind der Gleichungsfehler oder diverse Metriken der Kovarianz Matrix \mathbf{P} des Least-Squares Algorithmus.

Untersuchungen haben gezeigt, dass ein modifiziertes D-Kriterium der Kovarianz Matrix sehr robust ist, und sich zur Lichtbogendetektion eignet. Die verwendete Gütefunktion ist

$$criterion = \begin{cases} \frac{\det(\mathbf{P})}{\text{mean}(\det(\mathbf{P}))}, & \frac{\det(\mathbf{P})}{\text{mean}(\det(\mathbf{P}))} \leq 1 \\ 1, & \text{otherwise} \end{cases} \tag{25}$$

Um einen globalen Schwellwert zu finden, sind eine Vielzahl von Messungen mit Lichtbögen untersucht worden.

3.5 Modellbasierte Identifikation

Als Alternative zu regelbasierten Systemen können modellbasierte Systeme zur Detektion von Lichtbögen eingesetzt werden. Hierbei wird ein System nicht mittels bereits bekannten Regeln und Abhängigkeiten abgebildet und etwaige Anomalien als Fehlerfall interpretiert, sondern Modelle mittels Klassifikationsalgorithmen auf Basis von (meist durch Experten) a-priori klassifizierten Eingangssignalen trainiert. Diese Modelle können sowohl bekannte als auch neue Zusammenhänge abbilden, welche Domänenexperten zusätzliche Einblicke in das System ermöglichen. Hierfür existiert eine Vielzahl an potentiellen Klassifikationsalgorithmen, welche abhängig vom Problemfall und der jeweiligen Parametrierung unterschiedlich gute Ergebnisse liefern. Zusätzlich zur Auswahl und Konfiguration der Klassifikationsalgorithmen hat die Vorverarbeitung einen erheblichen Einfluss auf die Qualität der resultieren Modelle. Aufgrund dieser Gegebenheiten wurde im Rahmen des Forschungsprojekts FlashCheck, die Klassifikationsperformance zur Detektion von Lichtbögen von unterschiedlichen Algorithmen und Vorverarbeitungsroutinen untersucht.

3.5.1 Datenvorverarbeitung

Für die modellbasierte Lichtbogenidentifikation stehen ungefähr 300GB an Rohdaten, aufgezeichnet mit hochauflösenden 8MHz zur Verfügung. Durch diese Datenmenge wird je nach betrachtetem Klassifikationsalgorithmus ein naives Lernen auf sämtlichen Daten in praktikabler Zeit unmöglich. Aus diesem Grund müssen die Daten vorab reduziert werden. Hierfür wurden zwei unterschiedliche Ansätze untersucht: Downsampling und Piecewise Aggregate Approximation (PAA)¹. Beim Downsampling (siehe Abbildung 25) wird, mit äquidistantem Abstand, jedes n -te Element verwendet. Für den Anwendungsfall der Lichtbogendetektion wurde $n = 8000$ gewählt. Dadurch wird eine Reduktion der Daten um den Faktor 8000 erreicht und somit reduziert sich die Auflösung von 8MHz auf 1KHz. Dadurch ist eine Erkennung von Lichtbögen innerhalb von einer Millisekunde möglich.




Abbildung 25: Vereinfachte Darstellung von Downsampling (Verwendung jedes dritten Wertes)

¹ Keogh, E. J., & Pazzani, M. J. (2000, August). Scaling up dynamic time warping for datamining applications. In Proceedings of the sixth ACM SIGKDD international conference on Knowledge discovery and data mining (pp. 285-289).

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Für die PAA (siehe Abbildung 25) werden n konsekutive Datenpunkte zu einem Bin zusammengefasst und stellvertretend mit neu berechneten Kennzahlen beschrieben. Für den konkreten Fall der Lichtbogendetektion wurden sowohl der arithmetische Mittelwert als auch die Standardabweichung berechnet. Ebenso wie beim Downsampling wurde $n = 8000$ gewählt, da aber zwei Kennzahlen berechnet werden reduzieren sich die Daten um den Faktor 4000. Dabei entsteht aber ein geringerer Informationsverlust, da die Berechnung der neuen Kennzahlen auf den originalen Daten basieren.




Abbildung 26: Beispiel der Anwendung von Piecewise Aggregate Approximation. In diesem Fall werden der Durchschnitt (Avg.) und die Standardabweichung (Std) berechnet wobei je 4 konsekutive Datenpunkte dazu herangezogen werden.

Für das Training von Klassifikationsalgorithmen werden üblicherweise die Datenpunkte isoliert betrachtet, etwaige Informationen von früheren Zuständen sind nicht bekannt. Um dennoch Informationen aus der Vergangenheit zu berücksichtigen, kann Lagging verwendet werden. Hierbei (siehe Abbildung 27) werden zu jedem Datenpunkt zum Zeitpunkt t vergangenen Datenpunkte zum Zeitpunkt t_n hinzugefügt. Konkret wurden für die Lichtbogendetektion die Lags t_{-1} , t_{-10} und t_{-100} definiert (also die Datenpunkte vor 1ms, vor 10ms und vor 100ms).

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

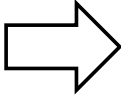
ID	Signal		ID	Signal	Lag1	Lag2	Lag3
1	10		1	10			
2	11		2	11	10		
3	8		3	8	11	10	
4	13		4	13	8	11	10
...			...				

Abbildung 27: Mittels Lagging werden Daten aus vorhergehenden Zeilen in zusätzliche Spalten aufgenommen. Auf diese Weise stehen in jeder Zeile Informationen aus der Vergangenheit zur Verfügung. In diesem konkreten Fall wird in jeder Zeile n für die Spalte „Lag1“ der Wert des Signals aus der Zeile $n-1$ verwendet.

Abhängig von der Funktionsweise des Klassifikationsalgorithmus kann die Verteilung der Daten einen großen Einfluss auf die Klassifikationsperformance haben. Aus diesem Grund wurde als letzter Vorverarbeitungsschritt eine Z-Score Standardisierung durchgeführt um die Daten in eine Normalverteilung zu transformieren. Hierfür wurde die Formel $x_{scaled}(i) = \frac{x_i - \mu}{\sigma}$ angewandt, wobei μ den Mittelwert und von x und σ die Standardabweichung von x beschreibt.

Diese definierten Vorverarbeitungsschritte ermöglichen eine Steigerung der Klassifikationsgenauigkeit, wobei nicht jede Vorverarbeitung für jeden Algorithmus sinnvoll und vorteilhaft ist. Deswegen wurden die Vorverarbeitungsschritte und Klassifikationsalgorithmen zusammen evaluiert um die beste Kombination für die Detektion von Lichtbögen zu identifizieren.

3.5.2 Klassifikationsalgorithmen

Für die Detektion von Lichtbögen mittels maschineller Lernverfahren und Klassifikationsalgorithmen liegen keine Erfahrung vor, welche Algorithmen gute Ergebnisse liefern. Aus diesem Grund, und um zusätzliches Wissen in diesem Anwendungsgebiet zu generieren, wurde eine Vielzahl unterschiedlicher Klassifikationsalgorithmen mit unterschiedlichen Parametrierung getestet. Die unterschiedlichen Algorithmen und ihre Parametrierung sind in Tabelle 1 gelistet und die erzielten Ergebnisse werden in Abschnitt 4.4 beschrieben.

Tabelle 1: Überblick der gewählten Klassifikationsalgorithmen und deren Parametrierung

Algorithm	Configuration	
Linear Discriminant Analysis²	-	
Quadratic Discriminant Analysis³	-	
Logistic regression⁴	Penalty	L1
	L1_Ratio	0.2, 0.4, 0.6, 0.8
Decision Tree Classification⁵	criterion	entropy
	splitter	best, random
	max_depth	2, 5, 7, 10, 12, 15, 20, 25
	max_features	sqrt, None
Random Forest Classification⁶	n_estimators	10, 25, 50, 100, 250, 500
	max_depth	None, 2, 5, 7, 10
	max_features	sqrt
Gradient Boosted Classification⁷	loss	deviance
	learning_rate	0.1, 0.05, 0.025, 0.01, 0.005
	max_depth	1, 2, 3, 5, 7
	max_features	sqrt
	criterion	mae
	n_estimators	100, 250, 500, 1000
Support Vector Machine Classification⁸	C	0.01, 0.1, 1, 10, 100, 1000
	kernel	poly, rbf
	gamma	scale
	degree	2, 3, 4

4 Ergebnisse und Schlussfolgerungen

4.1 Grundlegende Untersuchung der Lichtbogenphysik

4.1.1 Motivation

Um die entwickelnden Lichtbogen Detektions- Algorithmen verallgemeinern zu können sollte es ein Teilziel des Projektes sein, die Ursache für die Generierung von „Rauschen“ (in Strom und Spannung) oder der Auslenkung von Arbeitspunkten durch den Lichtbogen zu identifizieren. Damit kann eine Entscheidung

² McLachlan, G. J. (2004). *Discriminant analysis and statistical pattern recognition* (Vol. 544). John Wiley & Sons.

³ McLachlan, G. J. (2004). *Discriminant analysis and statistical pattern recognition* (Vol. 544). John Wiley & Sons.

getroffen werden, inwiefern andere Materialien möglicherweise Ursache für ein Versagen der Lichtbogen Detektion sein könnten.

4.1.2 Vorgehensweise

Es wurde ein Modellschalter entwickelt, mit dessen Hilfe elektrische Serienlichtbögen bei extrem kleinem Kontaktspace und verschiedenen Materialien (Kupfer, Aluminium, Stahl, Messing) generiert und dabei die Kontaktspannung und den Kontaktstrom mit ausreichender Grenzfrequenz gemessen werden konnte (siehe Abbildung 28).

Der Lichtbogen wurde mittels einer Hochgeschwindigkeitskamera (Makroaufnahmen) gefilmt. Mittels einer induktiven Methode erfolgte die Messung des Stromes mit einer Grenzfrequenz von 2 MHz. Die Spannungsmessung (Differentialastkopf) wies eine Grenzfrequenz von 100 MHz auf. Der Prüfstand wurde mittels einer Automatisierungssoftware derart automatisiert, dass ein Schrittmotor einen Kontakt gegen den Druck des anderen Kontaktes so lange verschob, bis ein Lichtbogen detektiert wurde. Dies triggerte die Hochgeschwindigkeitskamera sowie die Aufzeichnung der Messsignale. Der Modellschalter ist in Abbildung 29 dargestellt.

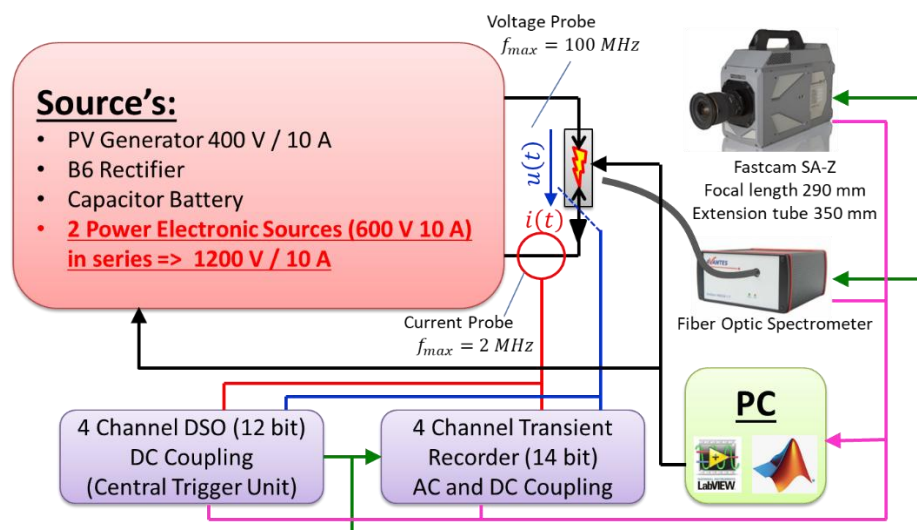


Abbildung 28: Messaufbau zur Untersuchung der Lichtbogenphysik bei engen Kontaktspace und verschiedenen Kontaktmaterialpaarungen.

⁴ Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied logistic regression (Vol. 398). John Wiley & Sons.

⁵ Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 1(1), 81-106.

⁶ Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.

⁷ Friedman, J. H. (2001). Greedy function approximation: a gradient boosting machine. *Annals of statistics*, 1189-1232.

⁸ Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine learning*, 20(3), 273-297.




Abbildung 29: Aufbau des Versuchsschalters.

4.1.3 Messergebnisse

Die Hochgeschwindigkeitsaufnahmen wurden mit den Messsignalen zu einem Film verlinkt, der die Lichtbogenstruktur zum jeweiligen Zeitpunkt im Spannungs- und Stromplot zeigt (siehe Abbildung 30).

Neben den erwarteten Lichtbogenphänomenen wurde auch eine sehr stabile Entladungsform identifiziert, die in der Literatur als „Glowing Contact“ beschrieben ist (siehe Abbildung 31). Diese stabile Plasmaentladung zeichnet sich durch geringes „Rauschen“ jeweils im Strom- bzw. im Spannungssignal aus (siehe Frequenzspektrn Abbildung 32). Mittels durchgeführter optischer Spektroskopie konnte gezeigt werden, dass es sich beim „Glowing Contact“ Phänomen um eine Plasmaentladung mit thermisch ionisiertem Plasma handelt.

4.1.4 Zusammenfassung der Resultate

Betrachtet man den gesamten Parameterbereich der durchgeführten Experimente so kann zusammenfassend bemerkt werden, dass durch spontane Auslenkungen des Gleichgewichtszustandes des Plasmakanals der elektrische Arbeitspunkt verändert und dadurch Rauschen generiert wird. Fehlen diese Auslenkungen (z.B. Eruptionen von siedendem Elektrodenmaterial) so ergibt sich eine sehr stabile Entladung mit wenig „Rauschen“. Eine erfolgreiche direkte Detektion eines Serienlichtbogens mittels Analyse des Frequenzspektrums ist damit stark vom Elektrodenmaterial und den Strömungsrandbedingungen abhängig.

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

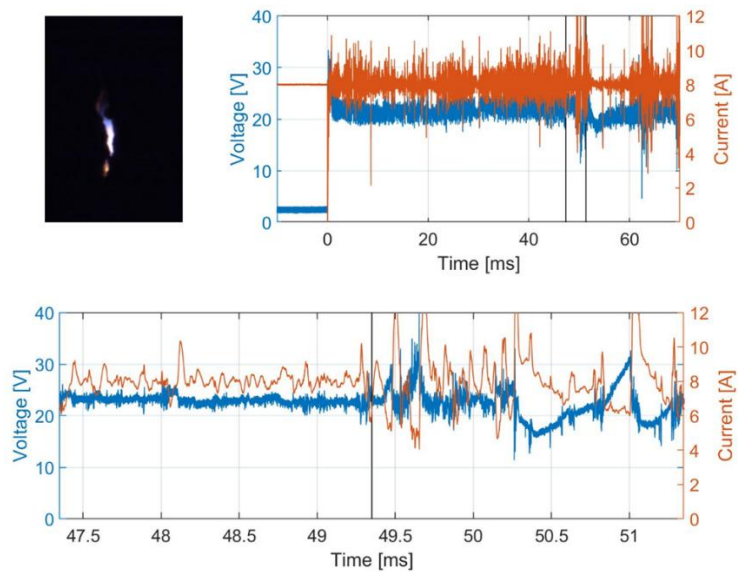


Abbildung 30: Messergebnis bei Kupferkontakten und einem Strom von 10 A. Das rechte obere Diagramm zeigt den gesamten Zeitverlauf der gemessenen Signale, links oben ist ein Einzelbild zum Zeitpunkt des vertikalen Indikators im unteren Diagramm (zeitlicher Ausschnitt aus dem obigen Diagramm) gezeigt.




Abbildung 31: „Glowing Contact“ zwischen Kupferelektroden bei einem Strom von 5 A.

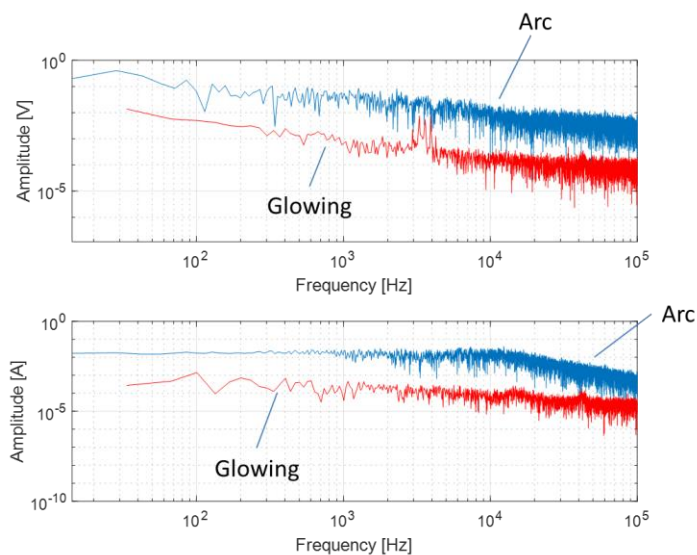


Abbildung 32: Vergleich des Spektrums des aufgezeichneten Stromes (8 A) bei einem „Glowing Contact“ und einem voll entwickelten Lichtbogen.

4.2 Compressed Sensing

Im folgenden Abschnitt zeigen wir, wie man die Theorie des modulierten Breitbandwandlers auf die Erkennung von Lichtbogenfehlern in PV-Systemen anwenden kann. Zunächst testen wir unsere Implementierung an einfachen Testsignalen, um zu untersuchen, ob sie zur Rekonstruktion verrauschter Signale geeignet ist. Dann wenden wir die MWC-Rekonstruktion auf Signale an, die aus einer Simulink-Simulation eines PV-Systems und eines Lichtbogengenerators stammen. Schließlich gehen wir zu Signalen über, die im Labor mit PV-Modulen und einem Lichtbogengenerator erzeugt wurden. Da die realen Signale für eine vollständige Rekonstruktion nicht ausreichend dünnbesetzt sind, schlagen wir einen alternativen Ansatz vor, um den Unterschied zwischen den Spektren eines Signals mit und ohne Lichtbogen detektieren zu können.

4.2.1 Test-Signale

Basierend auf Skripten, die von Mishali und Chen [44] bzw. Sahin [45] entwickelt wurden, implementierten wir eine Simulation des MWC in MATLAB, wobei die MMV-Variante des OMP-Algorithmus zur Lösung von (16) verwendet wurde. Wir testeten sie zunächst an einfachen Breitbandsignalen, deren Fourier-Transformation $X(f)$ eine Summe von $N = 4$ Boxcar-Funktionen mit Bandbreite $B = 25$ MHz ist,

$$x(t) = \sum_{i=1}^2 \sqrt{E_i B} \text{sinc}(B(t - \tau_i)) \cos(2\pi f_i(t - \tau_i)). \tag{26}$$

Dabei ist $\text{sinc}(x) = \sin(\pi x)/(\pi x)$, $E_i = \{1,2\}$, $\tau_i = \{0.4,0.7\}$, und die Trägerfrequenzen f_i wurden zufällig zwischen 0 und $f_{\text{NYQ}}/2 = 0.5$ GHz gewählt. Weiters wurde noch zufälliges Gaußsches Rauschen mit unterschiedlichem Signal-Rausch-Verhältnis (SNR) hinzugefügt. Abbildung 20 zeigt das ursprüngliche und das rekonstruierte Spektrum eines solchen Testsignals mit $\text{SNR} = 20$ dB. Die reduzierte numerische Dünnbesetztheit (15) für dieses Signal im Frequenzbereich, $\bar{s}(X) = 0.12$, ist etwas höher als der theoretische Wert für den unverrauschten Fall, der $2B/(f_{\text{NYQ}}/2) = 0.1$ beträgt. Man sieht, dass die Bereiche des Spektrums mit hoher Signalstärke fast vollständig übereinstimmen, abgesehen von kleineren Abweichungen an den Rändern der rekonstruierten Frequenzabschnitte (man beachte die logarithmische Skala).

In Abbildung 20 zeigen wir die Erfolgsrate p für die Rekonstruktion zufälliger Testfunktionen als Funktion der Anzahl der Kanäle m . Wie man sieht, beträgt die für $p > 0$ erforderliche Mindestanzahl an Kanälen $2N = 8$, was der minimalen theoretischen Abtastrate $2NB = 200$ MHz $= 0.2f_{\text{NYQ}}$ entspricht. Bei Signalen ohne Rauschen liegt die Erfolgsrate mit $m = 15$ Kanälen, was einer Gesamtabtastrate von $mf_s \approx 375$ MHz entspricht (etwa 38% der Nyquist-Rate), bereits nahe bei 1. Laut (19) ist der theoretische Minimalwert für eine stabile Rekonstruktion $m_{\text{min}} \approx 26$. Wenn das SNR zu groß ist, wie im zweiten Beispiel in Abbildung 20 rechts gezeigt, wird niemals eine perfekte Rekonstruktion erreicht.

4.2.2 Simulierte Lichtbogensignale

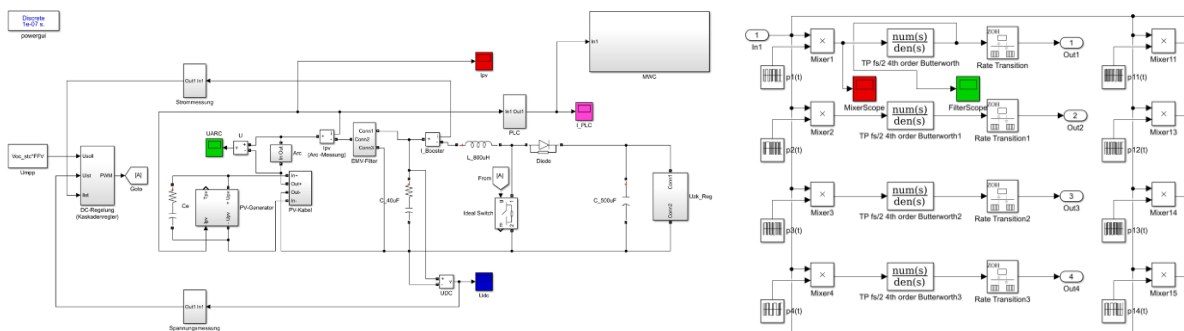


Abbildung 33: Links: Simulink-Modell eines PV-Systems mit Lichtbogen-Generator. Rechts: Ausschnitt aus dem Simulink-Modell des Modulated Wideband Converters.

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

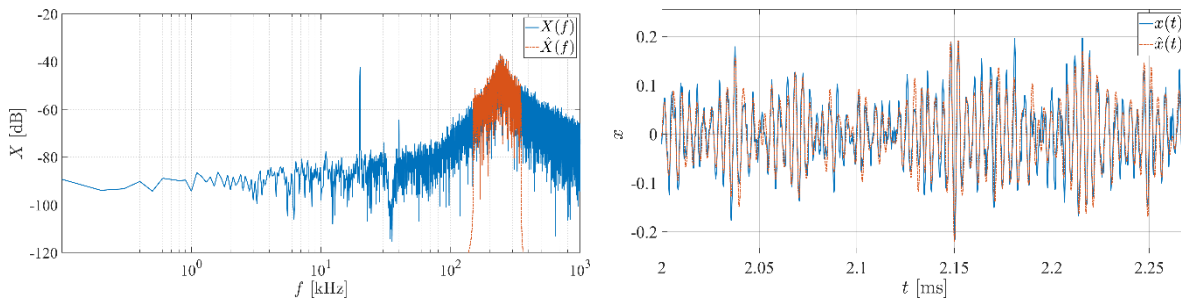


Abbildung 34: Ein simuliertes Lichtbogensignal und dessen Rekonstruktion mittels MWC-Implementierung in Simulink im Frequenzbereich (links) und einem Ausschnitt aus dem Zeitbereich (rechts). Die im MWC verwendete Nyquist- und Abtastfrequenz betragen 2 MHz bzw. 50 kHz.

Der nächste Schritt bestand nun darin, unsere MWC-Simulations- und Rekonstruktionsmethoden an einem Stromsignal zu testen, das mittels eines MATLAB/Simulink-Modell eines PV-Systems mit Störlichtbogen generiert wurde. Wir verwendeten dazu einen ebenfalls in Simulink modellierten MWC mit 30 verfügbaren Kanälen, um das in Abbildung 34 links gezeigte simulierte Lichtbogenspektrum $X(f)$ zu rekonstruieren. Das Spektrum weist eine relative numerische Dünnesetztheit von $\bar{s}(X) = 0.293$ auf, was relativ hoch ist und somit kein guter Indikator für die Eignung von CS zur zuverlässigen Rekonstruktion des Signals.

Wenn wir $x(t)$ als ein Einzelbandsignal mit einer geschätzten Bandbreite von 100 kHz betrachten, ergeben sich die Werte $N = 2$ und $f_s = f_p = B = 100$ kHz. Wir benutzen $m = 13$ der Kanäle, was laut (19) ausreichende ist. Unter Verwendung dieser Parameter findet der MWC die beiden größten Nicht-Null-Einträge im Vektor $z(f)$, die den Frequenzabschnitten mit dem größten Energieanteil entsprechen. Aufgrund der konjugierten Symmetrie bedeutet dies, dass in der positiven Hälfte des Spektrums ein Abschnitt mit einer Breite von 100 kHz rekonstruiert wird ($\hat{X}(f)$ in Abbildung 34 links). Obwohl wir keine exakte Rekonstruktion beobachten, wird der ausgeprägte Peak im Spektrum zwischen 200 und 300 kHz von $\hat{X}(f)$ korrekt wiedergegeben, und die Signale $x(t)$ und $\hat{x}(t)$ stimmen im Zeitbereich einigermaßen gut überein (siehe Abbildung 34 rechts).

4.2.3 Gemessene Lichtbogensignale

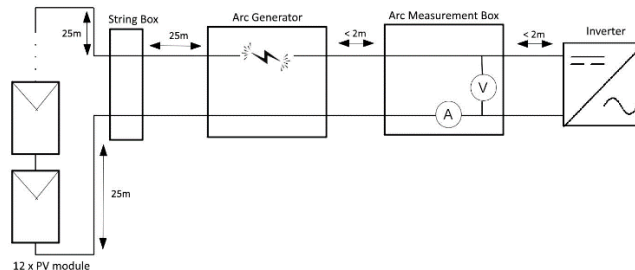


Abbildung 35: Experimenteller Aufbau zur Lichtbogenmessung.

Als nächstes versuchten wir dasselbe mit PV-Signalen, die im Labor gemessen werden. Der Versuchsaufbau wurde im Hinblick auf realistische Kabellängen entworfen und bestand aus 12 Photovoltaik-Modulen (Kioto KPV 260 PE poly, $U_{oc} = 37.99$ V, $I_{sc} = 8.99$ A) pro String, die 25 m von einer einfachen String-Kombibox (bis zu 3 Strings wurden direkt aneinander geklemmt), die wiederum 25 m von

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Lichtbogengenerator, Lichtbogenmesskasten und Wechselrichter (Fronius Primo Gen24 mit 5 kW Nennleistung, direkte Netzeinspeisung) entfernt war. Der Lichtbogengenerator wurde um eine lineare Translations-Stufe (Igus SLW-1660) mit abgerundeten Kupferelektroden herum aufgebaut (die Geschwindigkeit der Elektroden wurde in mehreren Schritten zwischen 0,1 mm/s und 20 mm/s variiert, die Gap-Länge zwischen 0,1 mm und 10 mm). Die Lichtbogen-Messbox bestand aus einem Differenzverstärker und einem an ein Messsystem (Red Pitaya STEMLab 125-14) angeschlossenen Hochfluss-Stromwandler. Sowohl Strom- als auch Spannungssignale (DC und AC, jeweils getrennt in einen nieder- und hochfrequenten Teil) wurden mit einer Abtastrate von 7,8 MS/s über einen Zeitraum von 4,3 s aufgenommen. Start- und Endpunkte des Lichtbogenereignisses in jedem Signal wurden ebenfalls aufgezeichnet. Einige der Messungen enthielten keinen Lichtbogen und wurden nicht in unsere Experimente mit einbezogen. Die deutlichsten Unterschiede zwischen Lichtbogen- und Nicht-Lichtbogensignalen wurden im hochfrequenten Spektrum des Stromsignals I_{DC} beobachtet. Es wurde daher als am besten zur Identifizierung von Lichtbögen geeignet angesehen und wird im Folgenden als Eingangssignal $x(t)$ verwendet.




Abbildung 36: Eine in einem Labor aufgenommene Lichtbogensignatur und deren Rekonstruktion nach MWC im Frequenzbereich (links) und im Zeitbereich (rechts).

Abbildung 36 zeigt das Ergebnis der MWC-Rekonstruktion einer Lichtbogensignatur, entnommen aus einem solchen Signal bei $t = 2.8$. Man erkennt, dass die Signalrekonstruktion noch weniger erfolgreich ist als für den simulierten Lichtbogen, obwohl die relative numerische Dünnbesetztheit $\bar{s}(X) = 0.269$ etwas geringer ist: Offensichtlich erfüllen auch die realen Signale die Anforderungen an ein dünnbesetztes Mehrbandsignal nicht gut genug. Wie man in Abbildung 36 sehen kann, ist der Peak im Spektrum weniger deutlich ausgeprägt und seine Stärke ist mit dem Teil des Signals unterhalb 100 kHz vergleichbar. Infolgedessen deckt der rekonstruierte Teil des Spektrums nun den Niederfrequenzbereich ab, der die Peaks von Hochspannungsleitungen einschließt und generell nicht so gut für die Erkennung von Lichtbögen geeignet ist. Wir kommen zu dem Schluss, dass das Ergebnis des Rekonstruktionsschritts nicht geeignet ist, um zwischen einem PV-Signal mit und ohne Lichtbogen zu unterscheiden.

Um unser Ziel weiter zu verfolgen, benötigten wir einen neuen Ansatz. Aufgrund des erhöhten Rauschens ist davon auszugehen, dass Signale aus realen Systemen eine noch geringere Dünnbesetztheit aufweisen als die im Labor gemessenen. Anstatt eine vollständige Rekonstruktion des Signals anzustreben, konzentrieren wir uns daher stattdessen auf einen kleinen Abschnitt des Signalspektrums, in dem das Lichtbogenereignis deutlich zu erkennen ist, und leiten das Signal vor der Anwendung des MWC durch einen Bandpassfilter, wodurch die Dünnbesetztheit des Spektrums erhöht wird. Um die Durchführbarkeit

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

dieser Methode zu testen, filterten wir die Laborsignale mit digitalen Bandpassfiltern unterschiedlicher Breite und wendeten dann den MWC und Rekonstruktion an. Abbildung 37 zeigt ein Beispiel, bei dem das bandpassgefilterte Signal mit hoher Genauigkeit rekonstruiert wird.

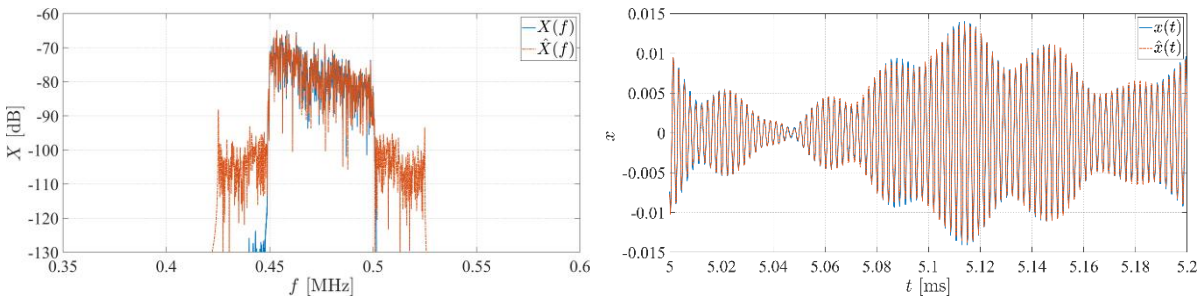


Abbildung 37: Bandpassgefiltertes Lichtbogensignal gemeinsam mit seiner Rekonstruktion nach MWC im Frequenzbereich (links, man beachte die logarithmische Skala) und im Zeitbereich (rechts).

Als nächstes sind zwei Punkte zu beachten. Zum einen müssen wir ein zeitabhängiges Merkmal des rekonstruierten Signals bestimmen, das für die Lichtbogenerkennung verwendet werden kann, und zum anderen müssen wir herausfinden, welcher Teilbereich des Spektrums dafür am besten geeignet ist. Werfen wir zunächst einen Blick auf das Spektrogramm eines typischen Lichtbogensignals. Wir multiplizieren das Signal mit einem Hann-Fenster $w(t)$ mit einer Breite von $T_w = 1$ zum Zeitpunkt τ und berechnen dann die Fourier-Transformation, was die Kurzzeit-Fourier-Transformation (Short Time Fourier Transformation, STFT),

$$X(\tau, f) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-2\pi jft} dt, \tag{27}$$

ergibt. Wenn wir den quadrierte Betrag $|X(\tau, f)|^2$ von (27), die spektrale Leistungsdichte von $x(t)$, für $\tau \in [t_{\min}, t_{\max}]$ (den Zeitbereich des Signals) und $f \in [0, f_{\text{NYQ}}/2]$ auftragen, erhalten wir das Spektrogramm des Signals (Abbildung 38 links). Es ist offensichtlich, dass während des Lichtbogenereignisses das Leistungsspektrum eine drastische Veränderung erfährt. Um diese Tatsache auszunutzen, konzentrieren wir uns auf die zeitliche Variation der Signalleistung innerhalb eines endlichen Frequenzintervalls. Dazu teilen wir den positiven Teil des Spektrums \mathcal{F} in N_B gleich große Frequenzbänder $\mathcal{F}_i = [f_i, f_{i+1}]$ mit Bandbreite B , wobei $f_i = (i - 1)B$ und $N_B B = f_{\max}$. Die instantane Leistung des Signals im i -ten Band zum Zeitpunkt τ ist dann gegeben durch

$$P_i(\tau) = \int_{f_i}^{f_{i+1}} |X(\tau, f)|^2 df. \tag{28}$$

Abbildung 38 rechts zeigt die Signalleistung $P_{17}(\tau)$ für Band 17 von $N_B = 20$ Bändern mit Bandbreite $B = 50$ kHz, und demonstriert, dass Beginn und Ende des Lichtbogens deutlich erkennbar sind (die Dauer des Lichtbogenereignisses wird durch den grünen Bereich markiert).

Da unser Ziel die Erkennung der Lichtbogensignatur ist und nicht die Wiederherstellung des Originalsignals, und da die vollständige Rekonstruktion auch einen hohen Rechenaufwand verursacht, wäre es am besten, diese ganz zu vermeiden. Darüber hinaus kennen wir den Signalträger S bereits im

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Vorhinein, da wir ihn über den Bandpassfrequenzbereich selbst bestimmen können. Sei k der größte Index in S . Wenn man eine Anzahl N_s von MWC-Samples $y_i[n]$ über ein kurzes Fenster des Signals zum Zeitpunkt τ aufzeichnet, dann lässt sich mittlere Leistung im Frequenzabschnitt \mathcal{F}_k ,

$$P_z(\tau) = \frac{1}{N_s} \sum_{n=1}^{N_s} |\hat{z}_k[n]|^2, \tag{29}$$

durch Invertieren der CS-Gleichung (16) mittels (13) berechnen. Unter der Annahme, dass sich die Diskontinuität der in Abbildung 38 rechts gezeigten Bandleistung auch in der k -ten Komponente des dünnbesetzten gesampelten Signalvektors $\hat{z}_k[n]$ zeigen sollte, schlagen wir vor, $P_z(\tau)$ als charakteristisches Bandmerkmal für die Lichtbogenerkennung zu verwenden.

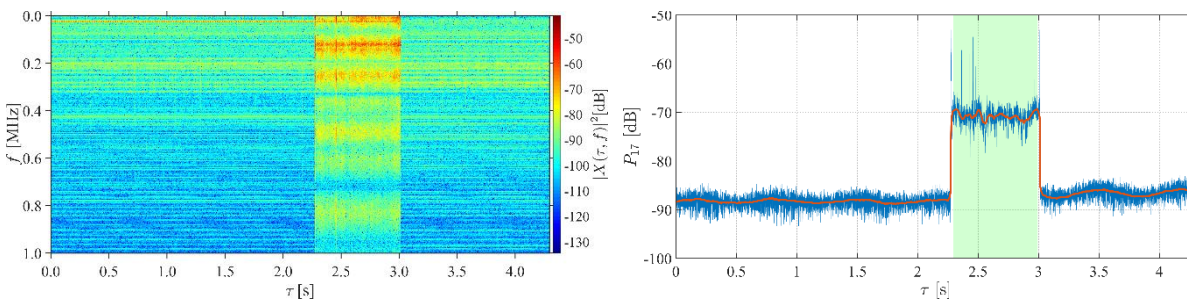


Abbildung 38: Links: Spektrogramm eines Lichtbogensignals. Der Lichtbogen tritt auf zwischen $\tau=2.29$ s und $\tau=2.99$ s. Rechts: Spektrale Leistung über die Zeit für Frequenzband 17 (800-850 kHz) des gleichen Signals. Blaue Kurve: ungefilterte Leistung; orange Kurve: median-gefilterte Leistung; der grüne Bereich markiert die Dauer des Lichtbogenerignisses.

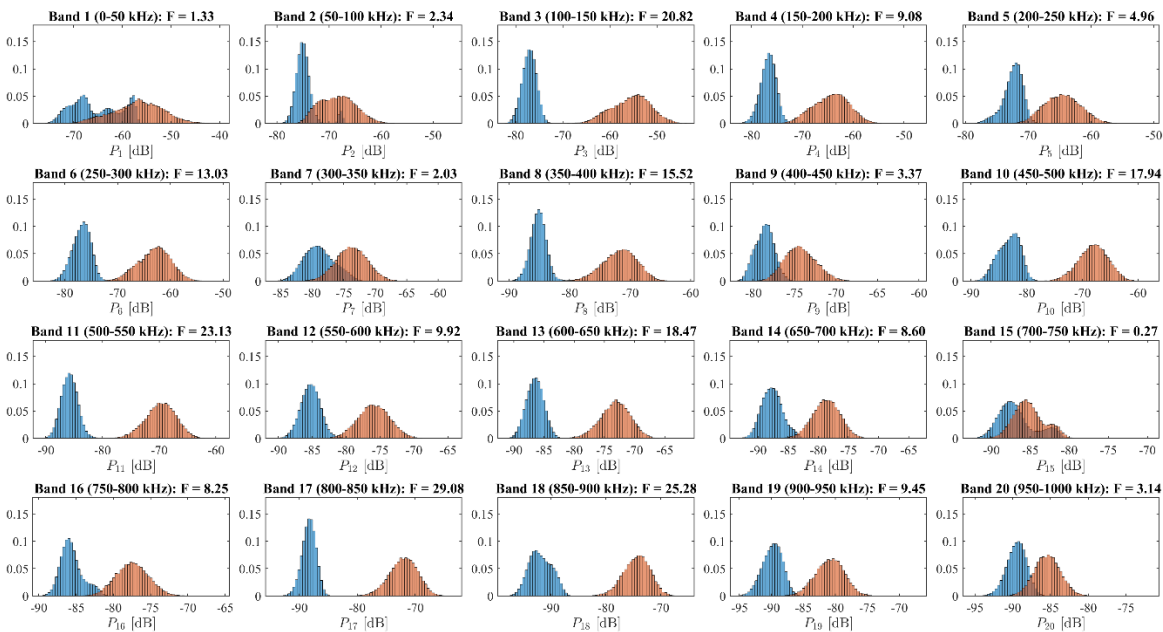


Abbildung 39: Normierte Histogramme der spektralen Bandleistung $P_i(\tau)$ (28). Blau: Messwerte vor dem Lichtbogenerignis; orange: Messwerte während des Lichtbogenerignisses. Die Titel der Diagramme zeigen die Bandposition und den Wert der Fisher-Diskriminante F .

4.2.4 Lichtbogenerkennung

Da der Beginn und die Dauer des Lichtbogenerignisses in unseren Testsignalen bekannt ist, können wir die Verteilung der Signalleistung vor und während des Lichtbogens für jedes Band im Spektrum ermitteln. Abbildung 39 zeigt die kumulierten Histogramme für 19 separate Signale aus derselben Messreihe in den 20 zuvor definierten Bändern. Bei der Berechnung des Lichtbogenhistogramms haben wir jeweils die ersten 30% und die letzten 10% der Dauer ignoriert, um sicherzustellen, dass wir nur die Zeitspanne einbeziehen, in der der Bogen stabil brennt. Um zu quantifizieren, wie gut ein Band für die Lichtbogenerkennung geeignet ist, bedienen wir uns einer Methode aus der Statistik: Die lineare Diskriminanzanalyse (LDA) [33] wird dazu eingesetzt, um die Trennbarkeit zweier Klassen von Beobachtungen zu messen. Konkret verwenden wir die Fisher'sche Diskriminanzfunktion [32], definiert als das Verhältnis der Varianz zwischen den Klassen zur Varianz innerhalb der Klassen,

$$F = \frac{(\mu_1 - \mu_2)^2}{\sigma_1^2 + \sigma_2^2}, \tag{30}$$

wobei angenommen wird, dass die innerhalb jeder Klasse beobachteten Werte einer Gaußschen Verteilung folgen.

Wie aus Abbildung 39 ersichtlich ist, schwankt F stark zwischen den Bändern und reicht von Werten nahe Null in Bereichen, in denen die Energieverteilung nicht durch die Anwesenheit des Lichtbogens beeinflusst wird, bis nahe 30 in Band 17, wo die beiden Histogramme vollständig getrennt sind und weit auseinander liegen. Für uns bedeutet das, dass sich für dieses Signal das Band zwischen 850 und 900 kHz am besten für die Lichtbogendetektion eignet. Ein einfaches Kriterium für das Vorhandensein eines Lichtbogens wäre nun, dass die charakteristische MWC-Leistung $P_z(\tau)$ einen Schwellwert von $\bar{\mu} = (\mu_1 + \mu_2)/2$ einmal oder eine bestimmte Anzahl aufeinanderfolgender Male überschreitet. Wenn sich die Standardabweichungen der beiden Verteilungen signifikant unterscheiden, ist natürlich eine differenziertere Wahl unter Berücksichtigung des Verhältnisses zwischen σ_1 und σ_2 vorzuziehen.




Abbildung 40: Charakteristische MWC-Bandleistung $P_z(\tau)$ über die Zeit für das Signal aus Abbildung 38 nach Bandpassfilterung zwischen 800 und 850 kHz, berechnet mit einer unterschiedlichen Anzahl von

Kanälen ($m=4,5,6$). Der grüne Bereich zeigt den Zeitraum des Lichtbogen-Ereignisses an. Ebenfalls dargestellt ist der vorgeschlagene Schwellwert $\bar{\mu}$ zur Lichtbogen-Detektion (orange gestrichelte Linie), der auf halbem Weg zwischen den jeweiligen Mittelwerten von P_z vor und während des Lichtbogen-Ereignisses liegt.

Abbildung 40 zeigt die charakteristische Bandleistung $P_z(\tau)$ für eine unterschiedliche Anzahl m von MWC-Kanälen, wobei das Signal aus Abbildung 38 bandpassgefiltert auf den Bereich 850-900 kHz mittels eines digitalen FIR-Filters, als Eingangssignal verwendet wurde. Während bei der kleinsten Anzahl von Kanälen ($m = 4$) die Spitzen in der Kurve noch recht groß sind, ist die Lichtbogensignatur für $m = 6$ bereits recht deutlich zu erkennen. Dieser Wert ist wesentlich kleiner als die durch (19) gegebene Zahl, $m_{\min} \approx 18.6$, die für eine stabile Blindrekonstruktion des Signals erforderlich wäre.

Die Werte im Diagramm wurden jeweils durch Abtastung des bandpass-gefilterten Signals in einem Fenster der Länge $T_w = 1$ ms mit m MWC-Kanälen und der Samplefrequenz $f_s = B = 50$ kHz gemäß (29) erzeugt. Dies wurde an 500 diskreten Zeitpunkten τ_i , gleichmäßig verteilt über die Signaldauer $T_s = 4.3$ s, durchgeführt, was in MATLAB 6.6 s in Anspruch nahm. Wird ein zusätzlicher Signalrekonstruktionsschritt durchgeführt, so erhöht sich diese Zahl auf 16.7 s, was einem Beschleunigungsfaktor von etwa 2,5 entspricht, wenn die Rekonstruktion weggelassen wird.

Für das oben beschriebene Erkennungskriterium werden nur ein oder wenige aufeinanderfolgende Werte von $P_z(\tau_i)$ benötigt, und da sich jeder Wert in Software in etwa 13 ms berechnen lässt, kann man davon ausgehen, dass unser Algorithmus, in Hardware implementiert, in der Lage wäre, den Beginn eines Lichtbogens in Echtzeit zu erkennen. Es sollte noch erwähnt werden, dass sich die in Abbildung 40 gezeigten Werte von $P_z(\tau)$ von den in Abbildung 38 und Abbildung 39 aufscheinenden Werten von $P_{17}(\tau)$ unterscheiden, da sie nur den Beitrag eines einzelnen Frequenzabschnitts zur Gesamtbandleistung enthalten. Der Abstand und die Varianz der Peaks im Histogramm (und somit der Wert der Diskriminante F) bleiben hingegen gleich.

Mit der oben beschriebenen Methode konnten wir für die mit unserem Versuchsaufbau gemessenen Bogensignale eine Detektionsrate von 100 % erreichen. Betrachtet man die besten derzeit verfügbaren Detektionsmethoden, die in [7] aufgelistet sind, ist dies eine Verbesserung im Vergleich z.B. zur FFT-Methode in [13]. Obwohl unsere Methode noch nicht in Hardware implementiert wurde, ist zu erwarten, dass die endgültige Erkennungszeit sogar noch kürzer sein wird als die dort genannte. Außerdem hat unsere Methode den Vorteil einer weitaus geringeren Abtastrate (50 kHz vs. 250 kHz). Einige Vorversuche mit wechselnder Sonneneinstrahlung zeigten auch, dass diese Art von normalen Signaländerungen keinen Einfluss auf das Spektrum haben und daher nicht als Lichtbögen klassifiziert werden. Unsere Methode lässt sich mit geringem zusätzlichem Aufwand auf eine Kombination von zwei oder mehr Bändern erweitern. Dazu muss man nur mehrere Bandpassfilter anwenden, die MWC-Parameter, insbesondere N und m , entsprechend anpassen und als Bedingung für das Auftreten eines Lichtbogens verlangen, dass alle charakteristischen Bandleistungen ihren jeweiligen Schwellenwert überschreiten. Eine solche Mehrband-Detektion wäre auch aus anderen Gründen vorteilhaft, da Signale bei höheren Frequenzen in großen PV-Installationen aufgrund großer Kabellängen zur Wellenausbreitung neigen, was zu Resonanzeffekten in verschiedenen Bändern führen kann. Darüber hinaus würde sie die Robustheit gegenüber externen Störungen, z.B. Telekommunikationskanälen, erhöhen. Auf diese Weise kann die

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Zuverlässigkeit des Detektionsalgorithmus auf Kosten einer höheren Gesamtabtastrate und komplexerer Hardware verbessert werden. Andererseits könnte auch die Anzahl der Kanäle weiter reduziert werden, wenn man eine höhere Abtastrate pro Kanal und zusätzlichen Rechenaufwand in Kauf nimmt, indem die am Ende von Kapitel 3.3.2 erwähnte Methode angewendet wird.

Da eine breite Palette von Lichtbogenparametern bei verschiedenen System-Sollwerten in die Messkampagne einbezogen wurde, gehen wir davon aus, dass die vorgeschlagene Methode bei verschiedenen Arten von Lichtbögen einsetzbar ist. Nichtsdestotrotz sind weitere Untersuchungen zu Störeffekten aufgrund großer Kabellängen sowie weitere quantitative Analysen erforderlich, um die vorgeschlagene Methode im Vergleich zum Stand der Technik bei der Niederfrequenz-Lichtbogendetektion vollends beurteilen zu können.

Ein weiterer Punkt, der erwähnt werden sollte, ist die Tatsache, dass das optimale Frequenzband für die Lichtbogendetektion zwischen verschiedenen PV-Systemen variieren kann. Bisher hatten wir nicht die Möglichkeit, unsere Methode z.B. mit anderen Systemtopologien zu testen. Es wird wahrscheinlich notwendig sein, die statistische Analyse der Leistungshistogramme mit annotierten Testsignalen für jeden neuen Typ von PV-Systemen zu wiederholen (oder detaillierte Simulationen durchzuführen), bevor die Methode dort zuverlässig angewendet werden kann.

4.3 Regelungsorientierte Identifikation

4.3.1 Messergebnisse

Für die Messkampagne wurde eine reale PV-Anlage verwendet. Zur Erzeugung der synthetischen (seriellen) Lichtbögen wurde Arc-Generator am Dach zwischen PV-Paneele und Inverter installiert. Das Set-Up ist in Abbildung 41 schematisch dargestellt.

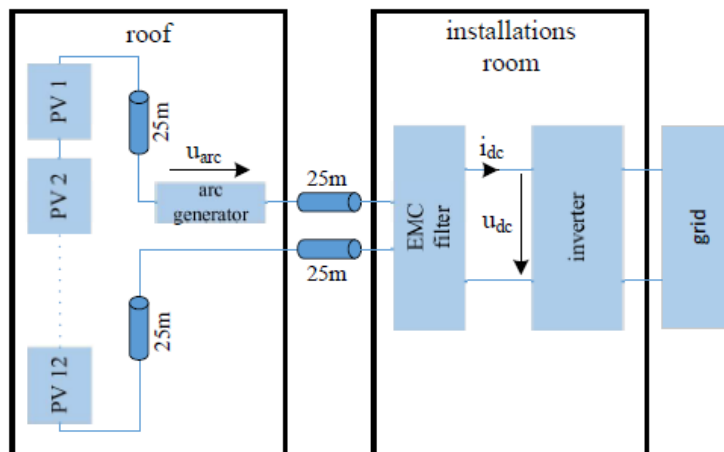


Abbildung 41: Setup Messkampagne

In Abbildung 42 ist im oberen Subplot das Gütefunktional (blau) mit dem Schwellwert (grün) dargestellt, während im unteren Teilbild die gemessene Lichtbogen Spannung und das Ergebnis des Detektionsalgorithmus abgebildet ist. Sobald der Wert des Gütefunktionals den Schwellwert unterschreitet, wird ein Lichtbogen detektiert. Interessant ist, dass der Lichtbogen jedenfalls zum Zündzeitpunkt erkannt wird, teilweise auch das Erlöschen des Lichtbogens, auf keinen Fall jedoch der

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

brennende Lichtbogen. Grund dafür ist, dass durch die permanente Anpassung des PV-Modells das „stationäre“ Verhalten des brennenden Lichtbogens nicht als solcher erkannt wird.

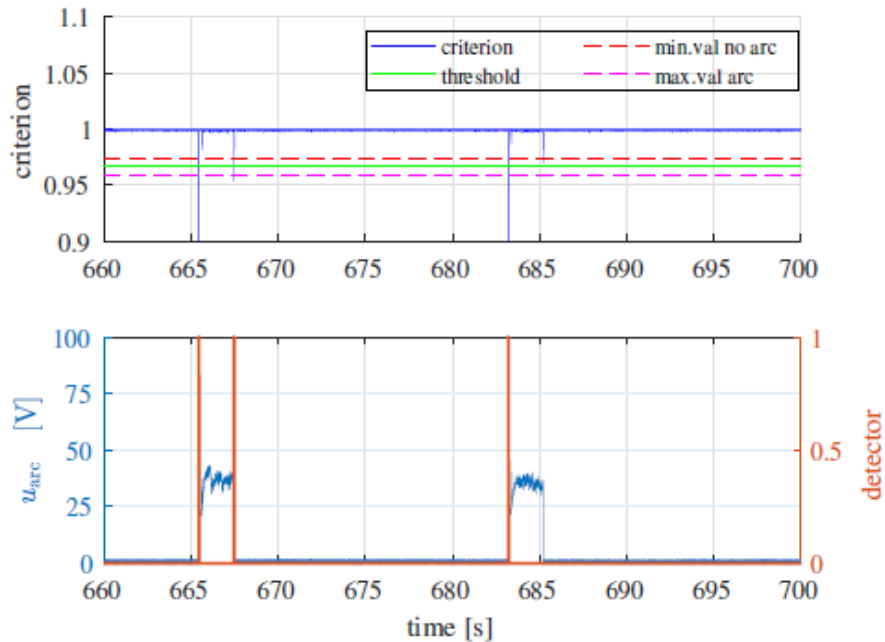


Abbildung 42: Gütefunktional, Lichtbogenspannung (zur Verifikation) und Detektorsignal

In Messausschnitt in Abbildung 43 wurden sechs Lichtbögen gezündet, die alle detektiert wurden.




Abbildung 43: Messung mit ziemlich konstanter Sonneneinstrahlung und Zündung von sechs Lichtbögen

In Abbildung 44 löst der Detektor bei ca. 520 s aus, obwohl kein Lichtbogen aufgetreten ist. Unerklärlicherweise schaltet der Inverter ab ($i_{DC}=0$), das Ersatzmodell ist ungültig und führt zu einer

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Fehlerdetektion. Die entwickelte Methode ist eben ein allgemeiner Fehlerdetektor, und kein reiner Lichtbogendetektor.




Abbildung 44: Messung mit konstanten Umweltbedingungen und einem Inverterfehler

In Messausschnitt in Abbildung 45 sind stark wechselnde Umwelteinflüsse sichtbar (Sonneneinstrahlung, Abschattung, etc.). Es werden alle vier Lichtbögen erkannt, während die lichtbogenähnliche Charakteristik im gemessenen Spannungs- und Stromsignal bei $t \approx 470s$ richtigerweise nicht als Fehler (Lichtbogen) detektiert wird.




Abbildung 45: Messung mit wechselnden Umweltbedingungen und vier Lichtbögen

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Im Vergleich zu konventionellen, meist FFT basierten, Detektionsmethoden wird mit dem im Projekt entwickelten Algorithmus ein Lichtbogen ca. 15-20 mal schneller erkannt.




Abbildung 46: Detektionszeit

4.3.2 Zusammenfassung und Schlussfolgerungen

Die wichtigsten Eigenschaften des entwickelten Detektors sind:

- Allgemeiner Fehlerdetektor, nicht nur für spezifische Störlichtbögen
- Sehr einfacher Detektor, ressourcenschonende Implementierung
- Flexibel in bestehende Hardware integrierbar
- Flexibel bzgl. der Messstellen von Spannung und Strom (Voraussetzung: strukturelle Identifizierbarkeit gewährleistet)

Hinsichtlich der Robustheit des Detektors sind in weiteren Untersuchungen u.a. folgende Punkte zu behandeln:

- Auswirkungen von Zusatzbeschaltung (Schutzbeschaltungen, Grid-Optimizer, PLC-Kommunikation, etc.) auf die Detektionsqualität
- Anlagenabhängigkeit des Detektionsschwellwertes
- Einschaltverhalten (was passiert wenn beim Hochfahren ein Lichtbogen auftritt)
- 3-phasige Wechselrichter (strukturelle Identifizierbarkeit)

4.4 Modellbasierte Identifikation

In Abbildung 47 sind die erzielten Ergebnisse bzgl. der Klassifikationsgenauigkeit sämtlicher Kombinationen zwischen den vorgestellten Vorverarbeitungsroutinen und den ausgewählten Klassifikationsalgorithmen dargestellt. Besonders hervorzuheben ist der starke Einfluss der gewählten Vorverarbeitungsroutine auf die Klassifikationsperformance. Die mittels PAA vorverarbeiteten Daten (Binned) sind dem naiven Downsampling-Ansatz deutlich überlegen, da für jeden der ausgewählten Klassifikationsalgorithmen damit signifikant bessere Ergebnisse erzielt wurden. Linear Discriminant Analysis und Quadratic Discriminant Analysis zeigen generell das geringste Potential zur Lichtbogendetektion, entsprechend kann von einem nichtlinearen Systemverhalten ausgegangen werden. Mit der Kombination aus Binning und Standardisation können durchgehend gute Ergebnisse erzielt werden. Die zusätzliche Inkludierung von Vergangenheitswerten mittels Lagging führte nur teilweise zu besseren Ergebnissen, erhöhte allerdings die Anzahl an Features um den Faktor drei, wodurch komplexere Klassifikationsmodelle entstehen.




Abbildung 47: Überblick der modellbasierten Klassifikationsleistung

Basierend auf diesen Ergebnissen wurden zwei Klassifikationsalgorithmen näher betrachtet und zwar Decision Trees (DT) und Random Forests (RF). Aufgrund ihrer ähnlichen Funktionsweise kann hier die Komplexität des Modells auf einfache Weise feinjustiert werden und eine ungefähre Bandbreite der Qualität bezüglich der Lichtbogendetektion geschätzt werden. Hierfür wurden vier Modelle trainiert, je zwei

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

DT und ein zwei RF. Sowohl die DT als auch die RF-Modelle wurden mit zwei unterschiedlichen Parametrierungen trainiert, nachfolgend als simpel und komplex bezeichnet. Der simple DT wurde mit einer Tiefe von 10 beschränkt, der simple RF auf 5 Bäume mit einer jeweiligen maximalen Tiefe von 5. Für die komplexen Modelle wurde die Tiefe nicht beschränkt, lediglich die Anzahl an Bäumen für den RF wurde auf 100 limitiert.

Die wichtigsten Ergebnisse sind in Tabelle 2 (Gesamtergebnisse auf Datenpunkt-Granularität) sowie in Abbildung 48 (Simpler DT) und Abbildung 49 (Komplexer RF) angegeben. Für die zwei letzteren Darstellungen wurden die Modelle auf den einzelnen Versuchsläufen eines jeden Testsetups ausgewertet und die Genauigkeit jeder dieser Auswertungen wurde in Boxplots zusammengefasst.

Die Ergebnisse zeigen einen großen Unterschied zwischen der Genauigkeit und dem F1-score auf, welcher sich bei den simplen Modellen stärker manifestiert als bei den komplexeren Modellen. Ausschlaggebend hierfür ist die schlechte Erkennungsrate von True-Positives in Kombination mit der geringen Anzahl an Lichtbögen (im Verhältnis zu der gesamten Datenbasis). Samples ohne Lichtbogen (welche ungefähr 85% der Daten ausmachen) konnten mit den simplen Modellen zu >96% korrekt klassifiziert werden, mit den komplexen Modellen zu >98%.

Tabelle 2: Überblick der Qualität der Lichtbogendetektion auf Datenpunkt-Granularität

			Arc		Non-Arc	
	Accuracy	F1	Detected	Not Detected	Detected	Not Detected
DT Simple	88.23%	0.473	37.05%	62.95%	96.76%	3.24%
DT Complex	96.23%	0.876	93.31%	6.69%	96.72%	3.28%
RF Simple	93.30%	0.876	58.29%	41.71%	99.14%	0.86%
RF Complex	97.71%	0.921	94.07%	5.93%	98.33%	1.67%

Arc-Samples (Test): 146,225
Non-Arcs Samples (Test): 877,111

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

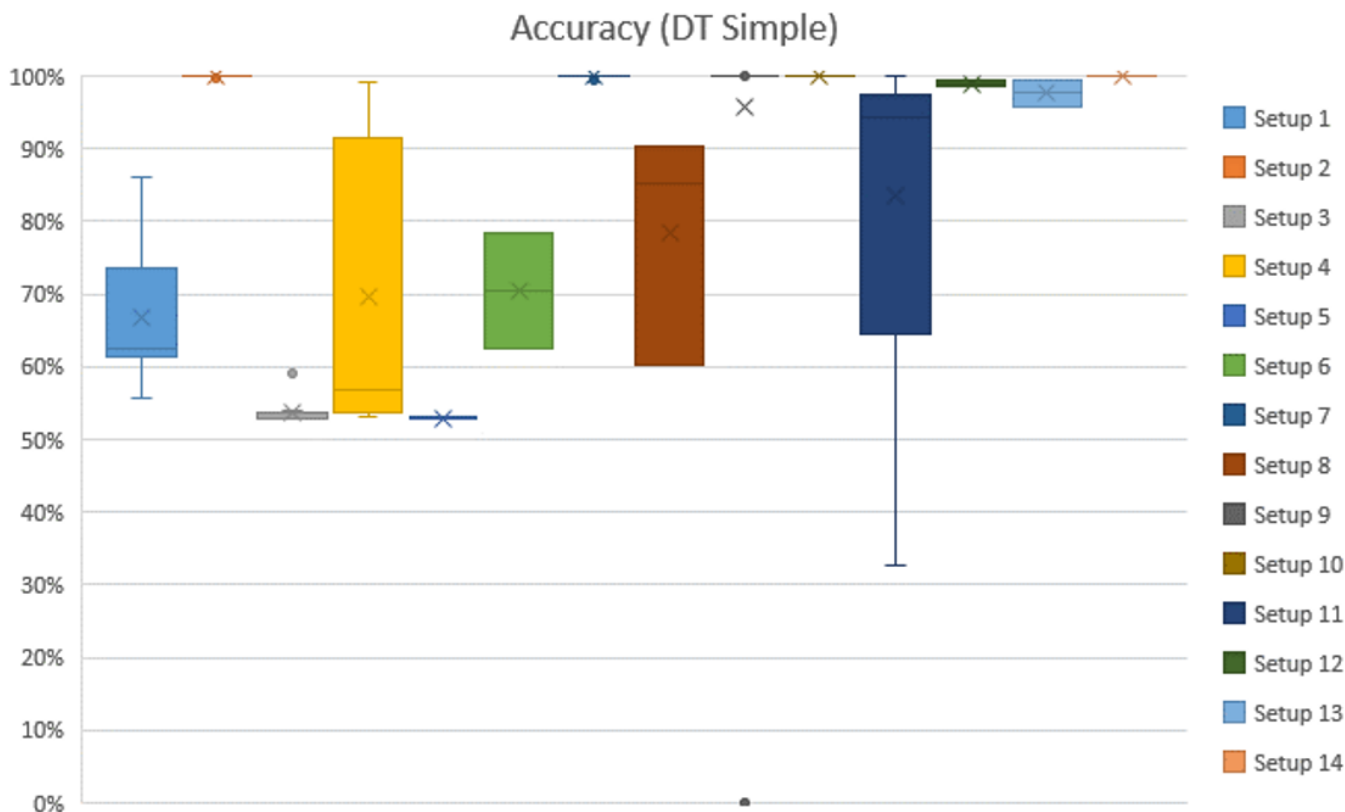


Abbildung 48: Genauigkeit eines simplen Decision Trees (DT), gruppiert nach Test-Setups.,

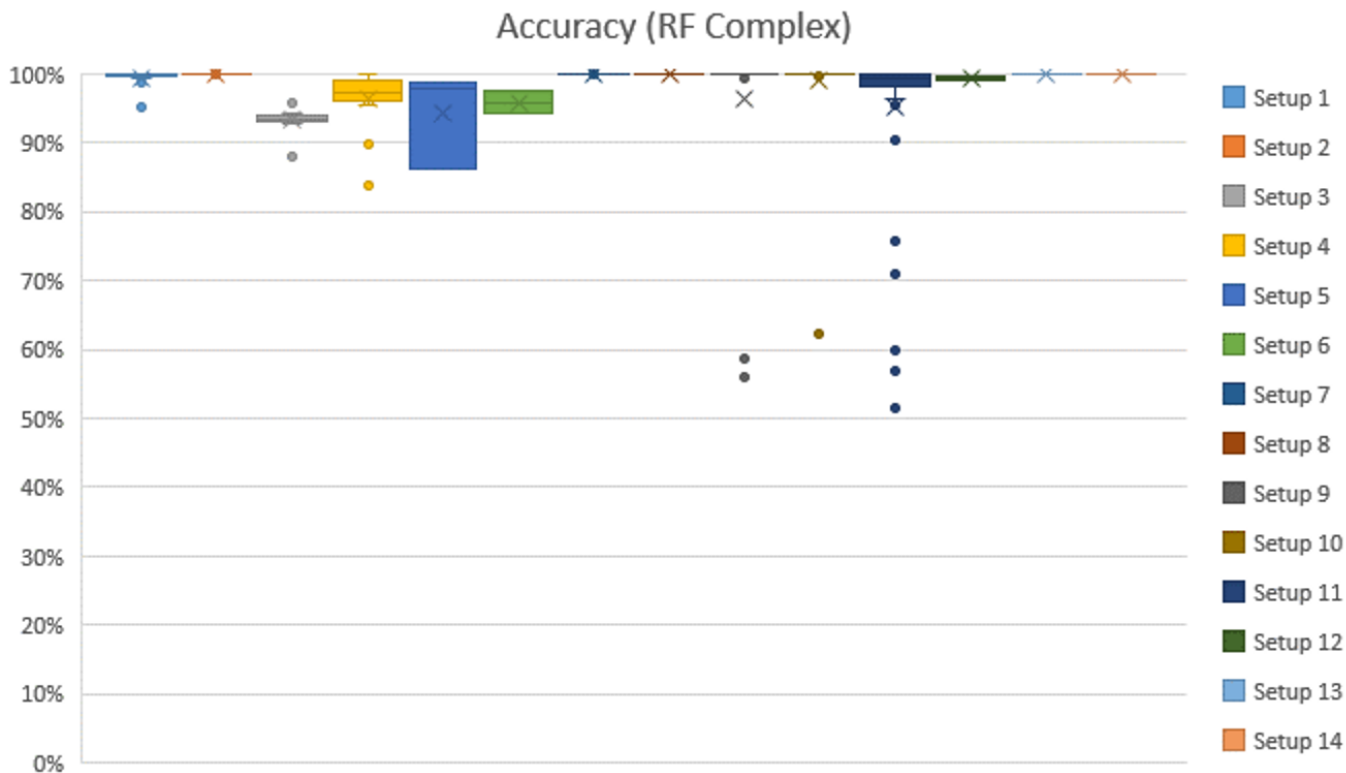


Abbildung 49: Genauigkeit eines komplexeren Random Forests, gruppiert nach den unterschiedlichen Test-Setups.

Eine nähere Betrachtung der Ergebnisse offenbart deutliche Unterschiede in der Genauigkeit zwischen den Setups. Während für die Setups 2, 7, 10 und 14 bereits durch den simplen DT eine annähernd perfekte Detektion auf sämtlichen Versuchsläufen erreicht wird, konnte der komplexe RF die Genauigkeit für sämtliche Setups noch weiter verbessern, dafür wird allerdings ein großer Teil der Interpretierbarkeit des Modells aufgegeben. Obwohl generell eine hohe durchschnittliche Genauigkeit von $> \sim 95\%$ erreicht werden konnte, gab es unerklärliche Ausreißer (siehe Setup 11). Diese Versuchsläufe sollten näher untersucht werden. Ebenfalls vielversprechend zeigen sich die Ergebnisse auf Tabelle 2. Über sämtliche Daten hinweg konnte ein vorhandener Lichtbogen innerhalb von 1ms mit einer Wahrscheinlichkeit von 94.07% detektiert werden, der Normalzustand wurde zu 98.33% korrekt erkannt.

Zusammengefasst wurde im Rahmen der Modellbasierten Identifikation die Kombination von unterschiedlichen Vorverarbeitungsroutinen und Klassifikationsalgorithmen untersucht. Die Ergebnisse zeigen einen signifikanten Einfluss der Vorverarbeitung bezüglich der resultierenden Modellqualität. Aufgrund der schlechten Ergebnisse der untersuchten linearen / quadratischen Modelle kann von einer hohen Nicht-Linearität ausgegangen werden. Mittels Binning konnten durchgehend bessere Ergebnisse als mit Downsampling erreicht werden, besonders die Kombination von Binning und Standardisierung wurde als vielversprechendste Kombination über sämtliche untersuchten Modellierungsverfahren identifiziert. In manchen Fällen konnten durch den Einsatz von Lagging noch bessere Ergebnisse erzielt werden, jedoch wurde die Anzahl an Features dadurch vervielfacht. Darauf aufbauend wurden entscheidungsbaum-basierte Klassifikationsalgorithmen mit 50% der vorhandenen Daten trainiert und deren Ergebnisse analysiert. Die komplexeren Modelle können innerhalb von 1ms Lichtbögen mit einer Wahrscheinlichkeit von 94.07% korrekt erkennen.

4.4.1 Klassifikationsergebnisse für Batteriespeichersysteme

Zur Evaluierung der Klassifikationsperformance und Prüfung der Generalisierbarkeit des Klassifikators wurde der Detektionsalgorithmus an Lichtbogensignalen in einem Batteriespeichersystem getestet. Die Datenvorverarbeitung (Normalisierung der Lichtbogen-daten und *Binning*) und der Klassifikator basierend auf einem *Random Forest Complex* Algorithmus wurden dabei von den erfolgreichen PV-Systemuntersuchungen übernommen.

Trotz der sehr hohen Klassifikationsperformance in PV-Systemen konnte der Random-Forest-Klassifikator in dem aufgebauten Batteriespeichersystem die Lichtbögen nicht verlässlich detektieren. Eine naheliegende Erklärung liegt in der fehlenden spezifischen Anpassung des Klassifikators an den Systemaufbau, der durch Rückkopplungen des Wechselrichters die Lichtbogensignale soweit beeinflusst, dass die Allgemeingültigkeit des Klassifikators zur Detektion von seriellen Lichtbögen schwindet. Dieses Ergebnis legt nahe, dass eine erfolgreiche Erkennung von Störlichtbögen in DC-Systemen mittel *Machine Learning* nur durch spezifisches Training am jeweiligen Systemaufbau möglich ist.

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG




Abbildung 50: Das Klassifikationsergebnis zu dem Lichtbogensignal aus Abbildung 17 zeigt eine sehr geringe Erkennungsrate. Nur wenige Millisekundenintervalle wurden richtig erkannt. Die Vertrauenswahrscheinlichkeit des Klassifikators beträgt in diesem Fall etwa 0,067.

Einzige Änderung des Ergebnisses wurde mit einer DC-Konstantstromquelle anstelle des Batteriespeichers erzielt, wobei die Verfahrgeschwindigkeit der Elektroden auf 25mm/Sekunde erhöht wurde. In diesem Fall erkannte der Klassifikator das Lichtbogensignal richtig, weil durch die höhere Verfahrgeschwindigkeit ein Rauschsignal des Stromquellenreglers überlagert wurde, das in das gesuchte Signalschema des Klassifikators passte.

Die Abbildung 50 zeigt das Klassifikationsergebnis passend zu Abbildung 17. Im Bild oben sind nur wenige Millisekundenintervalle orange markiert, die als Lichtbogensignaturen klassifiziert wurden.

Dieses Ergebnis legt nahe, dass ein Klassifikator basierend auf *Machine Learning* nur im trainierten Systemaufbau eine hohe Vertrauenswahrscheinlichkeit erreicht. Wird der Anwendungsbereich auf andere Netzsysteme erweitert, muss der Trainingsdatensatz mit Störlichtbogensignaturen aus diesem System ergänzt werden.

Es ist zu erwarten, dass eine Erweiterung des Trainingsvorganges auf verschiedenen DC-Netzsysteme zu einem signifikant höherem Trainingsaufwand oder bei gleichem Trainingsdatenvolumen mit Datensätzen aus beiden Systemen zu einer geringerer Klassifikationsperformance im jeweiligen Einzelsystem führt.

Aufgrund von Ressourcengründen konnten im vorgegebenen Projektzeitrahmen keine Trainingsversuche in beiden DC-Netzsystemen durchgeführt werden.

5 Ausblick und Empfehlungen

Im Rahmen des gegenständlichen Projektes wurde versucht, Störlichtbögen in Photovoltaikanlagen und Batteriesystemen mit unterschiedlichen Methoden zu detektieren.

Aufgrund der großen Gleichspannung und -ströme stellen Lichtbögen in PV-Systemen und Batteriespeichern ein potentiell Sicherheitsrisiko dar. Dies gilt besonders für serielle Lichtbögen, deren Auftreten zumeist durch defekte Kabel oder schlechte elektrische Verbindungen (Alterungseffekte, Umwelteinflüsse oder Tierverschleiß) verursacht wird. Die Folge daraus ist Brandgefahr für umliegende Teile aufgrund der hohen Temperatur dieser massiven Energieentladung.

Die verfügbaren Systeme zur Lichtbogendetektion am Markt sind sehr spezifische Systeme welche für die jeweilige Anwendung bis hinunter auf Komponentenebene angepasst sind. Insbesondere in größeren DC-Netzen ist eine verlässliche Erkennung bis heute nicht möglich. Selbst in PV-Anlagen sind die verfügbaren Schutzgeräte meist für bestimmte Anwendungsfälle, beispielsweise die Erkennung von normativ geforderten Lichtbögen konzipiert.

Im Rahmen dieses Projekts wurde versucht, ein generelles Konzept zur Erkennung von Störlichtbögen ohne Relevanz von Störeinflüssen, wie beispielsweise der Länge und Leitungsführung der elektrischen Kabel, zu entwickeln. Dazu wurde die Quelle-Lastabhängigkeit simulationstechnisch modelliert und ein modellbasierter Erkennungsansatz evaluiert. Um die notwendige Sensorik mittels einfacher, kostengünstiger Systeme zu ermöglichen, wurde der Einsatz von Compressed Sensing zur Erfassung der breitbandigen sporadischen Lichtbogensignale untersucht.

5.1 Datenerfassung

Zur Datenerfassung wurden unterschiedliche Systeme untersucht, welche die notwendigen Parameter zur nachfolgenden Detektion aufzeichnen sollten. Es wurde ein neuartiges System auf Basis eines RedPittaya entwickelt und in unterschiedlichen Konfigurationen sowohl im Laborbetrieb als auch auf einer realen Anlage evaluiert.

Wie bereits unter 3.1.3 angeführt, wurde die Kommunikation bzw. der Datentransfer unterschätzt. Für einen Rollout auf Feldsysteme wäre ein Breitband Mobilfunksystem (5G) erforderlich gewesen, welches zum Zeitpunkt der Entwicklung noch nicht zur Verfügung stand. Außerdem sollten die Messdaten entweder vorverarbeitet oder automatisiert auf eine Cloud übertragen werden.

5.2 Compressed Sensing

Es konnte gezeigt werden, dass Ideen aus dem Bereich des Compressed Sensing, insbesondere der Modulated Wideband Converter, für die zuverlässige und kostengünstige Erkennung von Lichtbogenfehlern in PV-Systemen eingesetzt werden können. Durch Auslassen der vollständigen Rekonstruktion des Signals kann sehr rasch ein charakteristisches Feature für ein vorausgewähltes HF-Band extrahiert werden, das für die Erkennung von Lichtbogenereignissen mittels Thresholding geeignet ist. In unseren Testsignalen konnten wir Lichtbogensignaturen im Frequenzbereich um 800 kHz unter

Verwendung von 6 MWC-Kanälen mit einer Sample-Frequenz von jeweils 50 kHz erkennen. Eine statistische Analyse der Bandleistungsverteilungen vor und während eines Lichtbogenerignisses zeigt, dass die Separierung der Histogramme in den einzelnen Bändern über mehrere Messungen mit demselben Aufbau konsistent bleibt. Wir sind daher zuversichtlich, dass die vorgeschlagene Methode ein gangbarer Weg ist, in Zukunft Lichtbogendetektoren für PV-Systeme zu bauen. Nichtsdestotrotz werden weitere Experimente, insbesondere mit potenziellen falsch-positiven Ergebnissen, etwa durch Abschattung oder Luftfahrzeuge, notwendig sein, um die Validität der Methode weiter zu untermauern, bevor sie in Hardware implementiert und vor Ort eingesetzt werden kann.

5.3 Modellbasierte Identifikation

Auf Basis der in 4.4 angeführten Ergebnisse, konnte bereits eine vielversprechende Qualität bezüglich Lichtbogendetektion erreicht werden. Mit den komplexeren Modellen konnte eine durchschnittliche Genauigkeit von >95% erreicht werden, wobei je nach Test-Setup Ausreißer festgestellt werden konnten. Mittels Detailanalyse der Ausreißer durch einen Domänenexperten sollten etwaige Aufzeichnungsfehler bzw. a-priori Fehlklassifikationen ausgeschlossen werden. Durch zusätzliches Feintuning der Vorverarbeitung (e.g. zusätzliche Features aus der Frequenz-Domäne oder weitere statistische Kennzahlen neben Durchschnitt und Standardabweichung) und des Modelltrainings können die Ergebnisse hier weiter verbessert werden. Als weitere Verbesserung kann mittels Postprocessing nicht nur die Klassifikationen für jedes Sample isoliert, sondern in Kombination mit den vorhergehenden Klassifikationen betrachtet werden. Dabei wird ein Ereignis (Lichtbogen) nicht sofort nach dem ersten positiven Klassifikationsergebnis als solches klassifiziert, sondern erst nach einer gewissen Anzahl konsekutiver positiver Vorhersagen. Dadurch reduziert sich die die Geschwindigkeit der Detektion, aber die Genauigkeit kann noch weiter gesteigert werden. Alternativ dazu können auch vergangene Werte (e.g. im Zeitraum von 100ms also 100 Datenpunkte) betrachtet werden und erst falls ein gewisser Schwellwert (e.g. 75%) davon positiv klassifiziert wurden, das Auftreten eines Lichtbogens angenommen werden.

5.4 Klassifikationsalgorithmik

Auf Basis der modellbasierten Identifikation wurden unterschiedliche Vorverarbeitungsroutinen und Klassifikationsalgorithmen untersucht. Die Ergebnisse zeigten dabei einen signifikanten Einfluss der Vorverarbeitung bezüglich der resultierenden Modellqualität. Aufgrund der schlechten Ergebnisse der untersuchten linearen / quadratischen Modelle kann von einer hohen Nicht-Linearität ausgegangen werden. Mittels Binning konnten durchgehend bessere Ergebnisse als mit Downsampling erreicht werden, besonders die Kombination von Binning und Standardisierung wurde als vielversprechendste Kombination über sämtliche untersuchten Modellierungsverfahren identifiziert muss jedoch weitere Forschung betrieben werden.

5.5 Erkennung in Batteriespeichersystemen

Im Rahmen des Projektes wurde auch die Erkennung von Lichtbögen in Batteriespeichersystemen als Grundlage zur Erkennung in allgemeinen DC-Netzen untersucht. Dabei wurden Probeläufe zur Messwerterfassung durchgeführt und entsprechende Identifikationsläufe angewandt. Allerdings konnte mit den entwickelten Ansätzen der Klassifikation keine zufriedenstellende Erkennungsquote realisiert werden.

Auf Basis der Ergebnisse konnte abgeleitet werden, dass ein Klassifikator basierend auf *Machine Learning* nur im trainierten Systemaufbau eine hohe Vertrauenswahrscheinlichkeit erreicht. Es wird deshalb ein umfangreicher Trainingsdatensatz notwendig, welcher vor allem in flexiblen und unbekanntem Systemen nur sehr aufwändig generiert werden kann. Die breite Anwendbarkeit konnte im Projekt aus Ressourcengründen nicht bestätigt werden und erfordert weiterführende Tätigkeiten.

6 Literaturverzeichnis

6.1 Referenzen

6.1.1 Compressed Sensing

- [1] C. Strobl and P. Meckler. Arc Faults in Photovoltaic Systems. In *2010 Proceedings of the 56th IEEE Holm Conference on Electrical Contacts*, pages 1–7, October 2010.
- [2] C. Luebke, T. Pier, B. Pahl, D. Breig, and J. Zuercher. Field test results of DC arc fault detection on residential and utility scale PV arrays. In *2011 37th IEEE Photovoltaic Specialists Conference*, pages 001832–001836, June 2011.
- [3] J. Johnson, C. Oberhauser, M. Montoya, A. Fresquez, S. Gonzalez, and A. Patel. Crosstalk nuisance trip testing of photovoltaic DC arc-fault detectors. In *2012 38th IEEE Photovoltaic Specialists Conference*, pages 001383–001387, June 2012.
- [4] V. Cattin, P. Perichon, J. Dahmani, B. Schwartzmann, and V. Heiries. Detection of electric arcs in large batteries. In *2013 World Electric Vehicle Symposium and Exhibition (EVS27)*, pages 1–9, November 2013.
- [5] C. Strobl. Arc Fault Detection - a Model-based Approach. In *ICEC 2014; The 27th International Conference on Electrical Contacts*, pages 1–6, June 2014.
- [6] A. Augeard, T. Singo, P. Desprez, and M. Abbaoui. Numerical methods for detecting DC arc fault in lithium-ion batteries. In *2015 IEEE 61st Holm Conference on Electrical Contacts (Holm)*, pages 39–46, October 2015.
- [7] Shibo Lu, B.T. Phung, and Daming Zhang. A comprehensive review on DC arc faults and their diagnosis methods in photovoltaic systems. *Renewable and Sustainable Energy Reviews*, 89:88–98, June 2018.
- [8] M. Zhen, W. Li, and S. Qiangang. The characteristics of DC arc faults current. In *2013 15th European Conference on Power Electronics and Applications (EPE)*, pages 1–9, September 2013.
- [9] J. Johnson, B. Pahl, C. Luebke, T. Pier, T. Miller, J. Strauch, S. Kuszmaul, and W. Bower. Photovoltaic DC Arc Fault Detector testing at Sandia National Laboratories. In *2011 37th IEEE Photovoltaic Specialists Conference*, pages 003614–003619, June 2011.
- [10] Y. Cao, J. Li, M. Sumner, E. Christopher, and D. Thomas. Arc fault generation and detection in DC systems. In *2013 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, pages 1–5, December 2013.
- [11] K. Xia, Z. He, Y. Yuan, Y. Wang, and P. Xu. An arc fault detection system for the household photovoltaic inverter according to the DC bus currents. In *2015 18th International Conference on Electrical Machines and Systems (ICEMS)*, pages 1687–1690, October 2015.

- [12] G. Seo, K. A. Kim, K. Lee, K. Lee, and B. Cho. A new DC arc fault detection method using DC system component modeling and analysis in low frequency range. In *2015 IEEE Applied Power Electronics Conference and Exposition (APEC)*, pages 2438–2444, March 2015.
- [13] S. Chae, J. Park, and S. Oh. Series DC Arc Fault Detection Algorithm for DC Microgrids Using Relative Magnitude Comparison. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 4(4):1270–1278, December 2016.
- [14] S. Chen and X. Li. PV series arc fault recognition under different working conditions with joint detection method. In *2016 IEEE 62nd Holm Conference on Electrical Contacts (Holm)*, pages 25–32, October 2016.
- [15] S. Chen, X. Li, and J. Xiong. Series Arc Fault Identification for Photovoltaic System Based on Time-Domain and Time-Frequency-Domain Analysis. *IEEE Journal of Photovoltaics*, 7(4):1105–1114, July 2017.
- [16] Z. Wang and R. S. Balog. Arc Fault and Flash Signal Analysis in DC Distribution Systems Using Wavelet Transformation. *IEEE Transactions on Smart Grid*, 6(4):1955–1963, July 2015.
- [17] Z. Wang and R. S. Balog. Arc fault and flash detection in DC photovoltaic arrays using wavelets. In *2013 IEEE 39th Photovoltaic Specialists Conference (PVSC)*, pages 1619–1624, June 2013.
- [18] H. Zhu, Z. Wang, and R. S. Balog. Real time arc fault detection in PV systems using wavelet decomposition. In *2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC)*, pages 1761–1766, June 2016.
- [19] Guo Yunmei, Wang Li, Wu Zhuoqi, and Jiang Binfeng. Wavelet packet analysis applied in detection of low-voltage DC arc fault. In *2009 4th IEEE Conference on Industrial Electronics and Applications*, pages 4013–4016, May 2009.
- [20] C. He, L. Mu, and Y. Wang. The Detection of Parallel Arc Fault in Photovoltaic Systems Based on a Mixed Criterion. *IEEE Journal of Photovoltaics*, 7(6):1717–1724, November 2017.
- [21] H. Braun, S. T. Buddha, V. Krishnan, A. Spanias, C. Tepedelenlioglu, T. Yeider, and T. Takehara. Signal processing for fault detection in photovoltaic arrays. In *2012 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1681–1684, March 2012.
- [22] Y. Gao, J. Zhang, Y. Lin, and Y. Sun. An innovative photovoltaic DC arc fault detection method through multiple criteria algorithm based on a new arc initiation method. In *2014 IEEE 40th Photovoltaic Specialist Conference (PVSC)*, pages 3188–3192, June 2014.
- [23] N. L. Georgijevic, M. V. Jankovic, S. Srdic, and Z. Radakovic. The Detection of Series Arc Fault in Photovoltaic Systems Based on the Arc Current Entropy. *IEEE Transactions on Power Electronics*, 31(8):5917–5930, August 2016.
- [24] W. Li, A. Monti, and F. Ponci. Fault Detection and Classification in Medium Voltage DC Shipboard Power Systems With Wavelets and Artificial Neural Networks. *IEEE Transactions on Instrumentation and Measurement*, 63(11):2651–2665, November 2014.

- [25] J. A. Momoh and R. Button. Design and analysis of aerospace DC arcing faults using fast fourier transformation and artificial neural network. In *2003 IEEE Power Engineering Society General Meeting (IEEE Cat. No.03CH37491)*, volume 2, pages 788–793 Vol. 2, July 2003.
- [26] Zhan Wang and Robert S. Balog. Arc fault and flash detection in photovoltaic systems using wavelet transform and support vector machines. In *2016 IEEE 43rd Photovoltaic Specialists Conference (PVSC)*, pages 3275–3280, Portland, OR, USA, June 2016. IEEE.
- [27] M. Li, S. Lu, D. Zhang, and B. T. Phung. Series Arc Fault Detection in DC Microgrid Using Hybrid Detection Method. In *IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society*, pages 265–270, October 2018.
- [28] A. Shekhar, L. RamÃ-rez-Elizondo, S. Bandyopadhyay, L. Mackay, and P. Bauera. Detection of Series Arcs Using Load Side Voltage Drop for Protection of Low Voltage DC Systems. *IEEE Transactions on Smart Grid*, 9(6):6288–6297, November 2018.
- [29] Q. Xiong, X. Liu, X. Feng, A. L. Gattozzi, Y. Shi, L. Zhu, S. Ji, and R. E. Hebner. Arc Fault Detection and Localization in Photovoltaic Systems Using Feature Distribution Maps of Parallel Capacitor Currents. *IEEE Journal of Photovoltaics*, 8(4):1090–1097, July 2018.
- [30] E. J. Candes, J. Romberg, and T. Tao. Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information. *IEEE Transactions on Information Theory*, 52(2):489–509, February 2006.
- [31] M. Mishali and Y.C. Eldar. From Theory to Practice: Sub-Nyquist Sampling of Sparse Wideband Analog Signals. *IEEE Journal of Selected Topics in Signal Processing*, 4(2):375–391, April 2010.
- [32] R. A. Fisher. The Use of Multiple Measurements in Taxonomic Problems. *Annals of Eugenics*, 7(2):179–188, September 1936.
- [33] Geoffrey J. McLachlan. *Discriminant Analysis and Statistical Pattern Recognition*. Wiley series in probability and statistics. Wiley-Interscience, 2004.
- [34] D. L. Donoho and X. Huo. Uncertainty principles and ideal atomic decomposition. *IEEE Transactions on Information Theory*, 47(7):2845–2862, November 2001.
- [35] B. Natarajan. Sparse Approximate Solutions to Linear Systems. *SIAM J. Comput.*, 24(2):227–234, April 1995.
- [36] S. Chen, D. Donoho, and M. Saunders. Atomic Decomposition by Basis Pursuit. *SIAM J. Sci. Comput.*, 20(1):33–61, January 1998.
- [37] S.G. Mallat and Zhifeng Zhang. Matching pursuits with time-frequency dictionaries. *IEEE Transactions on Signal Processing*, 41(12):3397–3415, December 1993.
- [38] Joel A. Tropp and Anna C. Gilbert. Signal Recovery From Random Measurements Via Orthogonal Matching Pursuit. *IEEE Transactions on Information Theory*, 53(12):4655–4666, December 2007.
- [39] T. Tony Cai and Lie Wang. Orthogonal Matching Pursuit for Sparse Signal Recovery With Noise. *IEEE Transactions on Information Theory*, 57(7):4680–4688, July 2011.

- [40] J. Chen and X. Huo. Theoretical Results on Sparse Representations of Multiple-Measurement Vectors. *IEEE Transactions on Signal Processing*, 54(12):4634–4643, December 2006.
- [41] M. Mishali and Y.C. Eldar. Reduce and Boost: Recovering Arbitrary Sets of Jointly Sparse Vectors. *IEEE Transactions on Signal Processing*, 56(10):4692–4702, October 2008.
- [42] Miles E. Lopes. Estimating Unknown Sparsity in Compressed Sensing. *arXiv:1204.4227 [cs, math, stat]*, April 2012. arXiv: 1204.4227.
- [43] M. Mishali and Y.C. Eldar. Blind Multiband Signal Reconstruction: Compressed Sensing for Analog Signals. *IEEE Transactions on Signal Processing*, 57(3):993–1009, March 2009.
- [44] M. Mishali and Y. Chen. The Modulated Wideband Converter: Sub-Nyquist Sampling of Sparse Wideband Analog Signals (Web Page), 2010.
- [45] Alphan Āzahin. Modulated Wideband Converter (Blog Entry), January 2015.

6.1.2 Modellbasierte Identifikation

- Affenzeller, M., Winkler, S. M., Kronberger, G., Kommenda, M., Burlacu, B., & Wagner, S. (2014). Gaining deeper insights in symbolic regression. *Genetic Programming Theory and Practice XI, Springer New York*, 175-190.
- Affenzeller, M., Winkler, S., Wagner, S., & Beham, A. (2009). Genetic Algorithms and Genetic Programming: Modern Concepts and Practical Applications. *Boca Raton, FL, USA: CRC Press*.
- Augeard, A., Singo, T., Desprez, P., & Abbaoui, M. (2015). Numerical methods for detecting DC arc fault in lithium-ion batteries. *2015 Proceedings of the 61st IEEE Holm Conference on Electrical Contacts*. San Diego, CA: IEEE.
- Boico, C., & Oberhauser, F. (2011). *SolarMagic SM73201 DC Arc Detection Evaluation Board Documentation*. Von <http://www.ti.com/lit/an/snoa564a/snoa564a.pdf> abgerufen
- Breiman, L. (2001). Random Forests. *Machine Learning*, 5-32.
- Brooks, B. (2011). The Bakersfield Fire. *SolarPro 4.2, Feb/Mar 2011*.
- Candes, E. J., & Wakin, M. B. (2008). An introduction to compressive sampling. *IEEE Signal Processing Magazine*, 21-30.
- Candes, E. J., Romberg, J., & Tao, T. (2006). Robust uncertainty principles: exact signal reconstruction from highly incomplete frequency information. *IEEE Transactions on Information Theory*, 489-509.
- Cattin, V., Perichon, P., Dahmani, J., Schwartzmann, B., & Heiries, V. (2013). Detection of electric arcs in large batteries. *Electric Vehicle Symposium and Exhibition (EVS27)* (S. 1-9). Barcelona: IEEE.
- Chen, X., Yu, Z., Hoyos, S., Sadler, B. M., & Silva-Martinez, J. (2011). A Sub-Nyquist Rate Sampling Receiver Exploiting Compressive Sensing. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 507-520.
- Dahmani, J., Cattin, J., & Perichon, P. (2015). *United States of America Patentnr. US20150061696*.
- I. Daubechies, M. Defrise, and C. De Mol. An iterative thresholding algorithm for linear inverse

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

problems with a sparsity constraint. *Comm. Pure Appl. Math.*, 57:1413-1457, 2004.

Donoho, D. L. (2006). Compressed sensing. *IEEE Transactions on Information Theory*, 1289-1306.

Draper, N. R., & Smith, H. (1966). *Applied Regression Analysis, 3rd edition*. Wiley-Interscience.

Duarte, M. F., & Eldar, Y. C. (2011). Structured Compressed Sensing: From Theory to Applications. *IEEE Transactions on Signal Processing*, 4053-4085.

M.A. T. Figueiredo, R.D. Nowak, and S. J. Wright. Gradient projection for sparse reconstruction: Application to compressed sensing and other inverse problems. *IEEE J. Sel. Top. Signa.*, 1:586–597, 2007.

Fraunhofer-Institut für Solare Energiesysteme ISE. (7. Februar 2013). Forschungsprojekt Sicherheit von Photovoltaikanlagen. *Photovoltaik-Brandschutz -- Fakten statt Phantome*. Presseinformation 5/13.

A.C. Gilbert, M. J. Strauss, and R. Vershynin. One sketch for all: Fast algorithms for Compressed Sensing. *In Proc. 39th ACM Symp. Theory of Computing (STOC), San Diego, CA, 2007*.

Glück, T., Kemmetmüller, W., Tump, C., & Kugi, A. (2011). A novel robust position estimator for self-sensing magnetic levitation systems based on least squares identification. *Control Engineering Practice*, 146-157.

Haeberlin, H. (2010). Arc Detector as an External Accessory Device for PV Inverters for Remote Detection of Dangerous Arcs on the DC Side of PV Plants. *European Photovoltaic Solar Energy Conference Valencia*. Spain.

Holland, J. H. (1975). *Adaptation in Natural and Artificial Systems*. University of Michigan Press.

Hornby, G. S., 2006. Alps: The age-layered population structure for reducing the problem of premature convergence. *In: Proceedings of the 8th Annual Conference on Genetic and Evolutionary Computation, ACM, New York, NY, USA, GECCO '06, pp. 815–822*.

Ji, L. (2009). PV Fire: Experience and Studies. *International Photovoltaic Reliability Workshop II, 31 July, 2009*.

Johnson, I., Pahl, B., Luebke, c. J., Pier, T., Miller, T., Strauch, I., & Kuszmaul, S. a. (2011). Photovoltaic DC arc fault detector testing at Sandia National Laboratories. *37th Photovoltaic Specialists Conference, Seattle, WA, 19-24 June 2011*. IEEE.

Johnson, J., & Kang, J. (2012). Arc-fault detector algorithm evaluation method utilizing prerecorded arcing signatures. *Photovoltaic Specialists Conference (PVSC) (S. 1378-1382)*. IEEE.

Johnson, J., Montoya, M., McCalmont, S., Katzir, G., Fuks, F., Earle, J., Granata, J. (2012). Differentiating series and parallel photovoltaic arc-faults . *Photovoltaic Specialists Conference (PVSC), 2012 38th IEEE (S. 000720 - 000726)*. Austin, TX : IEEE.

Johnson, J., Oberhauser, C., Montoya, M., Fresquez, A., Gonzalez, S., & Patel, A. (2012). Crosstalk nuisance trip testing of photovoltaic DC arc-fault detectors. *Photovoltaic Specialists Conference (PVSC), 2012 38th IEEE (S. 001383 - 001387)*. IEEE.

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

Keijzer, M. (2003). Improving symbolic regression with interval arithmetic and linear scaling. *In Genetic programming* (S. 70-82). Springer Berlin Heidelberg.

Kommenda, M., Kronberger, G., Wagner, S., Winkler, S. M., & Affenzeller, M. (2012). On the architecture and implementation of tree-based genetic programming in HeuristicLab. *GECCO (Companion)*, 101-108.

Mayr, S., Grabmair, G. und Reger, J., „Fast Model-Based Fault Detection in Single-Phase Photovoltaic Systems,“ in Proceedings of 45th IEEE Industrial Electronics Society (IECON), Lisbon, 2019.

6.2 Online

[1] *Heuristic Lab* url:<http://dev.heuristiclab.com>

[2] *Nutonian* <http://nutonian.com>

[3] *Evolved Analytics* <http://evolved-analytics.com>

[4] *Red Pitaya documentation.* 2018. url:
<http://rpdocs.readthedocs.io/en/latest/developerGuide/software/fpga.html>

[5] *Red Pitaya GitHub page.* 2018. url: <https://github.com/RedPitaya/RedPitaya/tree/release-v0.94>

[6] *LEM CKSR 50 Sensor* url: <https://www.lem.com/en/cksr-50np>

[7] *Fast Fourier Transform v9.0 LogiCORE IP Product Guide.* 2017. url:
https://www.xilinx.com/support/documentation/ip_documentation/xfft/v9_0/pg109-xfft.pdf

Energieforschungsprogramm - 3. Ausschreibung

Klima- und Energiefonds des Bundes – Abwicklung durch die Österreichische Forschungsförderungsgesellschaft FFG

7 Kontaktdaten

Fronius International GmbH

Philipp Rechberger
Günter Fronius Straße 1
4600 Thalheim b. Wels
+43 664 88635562
Rechberger.philipp@fronius.com

EATON Industries GmbH

Hartwig Plach
Eugenia 1
3943 Schrems
+43 50868-1416
hartwigplach@eaton.com

FH OÖ F&E GmbH

Gernot Grabmair
Roseggerstraße 15
4600 Wels
+43 50804-43490
gernot.grabmair@fh-wels.at

RISC Software GmbH

Wolfgang Fenz
Softwarepark 35
4232 Hagenberg
+43 7236 33430
wolfgang.fenz@risc-software.at