



Schweizerische Eidgenossenschaft
Confédération suisse
Confederazione Svizzera
Confederaziun svizra

Eidgenössisches Departement für
Umwelt, Verkehr, Energie und Kommunikation UVEK
Bundesamt für Energie BFE
Energieforschung

Jahresbericht 2020

LoCoSol-LowCost-Monitoring von thermischen Solaranlagen



Datum: 20.12.2020

Ort: Muttenz

Auftraggeberin:

Bundesamt für Energie BFE
Forschungsprogramm Solarthermie und Wärmespeicherung
CH-3003 Bern
www.bfe.admin.ch
energieforschung@bfe.admin.ch

Auftragnehmer/in:

Fachhochschule Nordwestschweiz, FHNW
Hofackerstrasse 30
CH-4132 Muttenz
<https://www.fhnw.ch/de>

Energie Zukunft Schweiz AG
Viaduktstrasse 8
CH-4051 Basel
www.energiezukunftsueiz.ch

Autor/in:

Dominique Kunz, FHNW, dominique.kunz@fhnw.ch
Ralph Eismann, FHNW, ralph.eismann@fhnw.ch
Joachim Hofmann, FHNW, joachim.hofmann@fhnw.ch
Bernd Sitzmann, EZS, b.sitzmann@energiezukunftsueiz.ch
John Dickinson, EZS, j.dickinson@energiezukunftsueiz.ch

BFE-Bereichsleitung:

Andreas Eckmanns, andreas.eckmanns@bfe.admin.ch

BFE-Programmleitung:

Dr. Elimar Frank, elimar.frank@frank-energy.com

Betreff:

Jahresbericht LoCoSol 2020

BFE-Vertragsnummer:

SI/501965-01

Für den Inhalt und die Schlussfolgerungen sind ausschliesslich die Autoren dieses Berichts verantwortlich.



Zusammenfassung

Eine Einführung in die Thematik wurde in einem Workshop erarbeitet, bei dem die bestehenden Daten von Energie Zukunft Schweiz (EZS) zur Funktionskontrolle thermischer Solaranlagen visualisiert und die entsprechenden Fehlerbilder erläutert wurden. Die Begehung einer Solaranlage, bei der ein LoRa-Sensor bereits installiert ist, ermöglichte den Praxisbezug und machte die Problematik von Solaranlagen erlebbar.

Das bestehende Monitoring-System von EZS wurde auf eine neue Serverplattform als Produktivsystem kopiert. Ein zweites System wurde als Entwicklungssystem aufgesetzt. Das Entwicklungssystem erhält die gespiegelten Daten. Durch dieses Vorgehen wird sichergestellt, dass das Produktivsystem nicht durch die Entwicklungsarbeiten gefährdet wird.

Die Fehlerbilder bzw. Testfälle, die es automatisch zu erkennen gilt, sind ausformuliert. Es stehen Daten von 52 Anlagen zur Verfügung, bei denen 17 mit Fehlern aufwarten. Dies ist eine genügende Datenbasis für die Projektarbeit.

Die Erkennungsalgorithmen wurden entwickelt und hinsichtlich ihrer Eignung für diese Aufgabenstellung bewertet. Es wird ein «supervised learning» "Long short-term Memory" (LSTM) Algorithmus, unter der Zuhilfenahme der «Framework» Tensorflow & Keras, eingesetzt. Die Erkennung von ersten Testfällen sind implementiert und werden an den vorhanden Datensätzen getestet.

Das Finalisieren der Programmierung und das Testen der automatischen Fehlererkennung sind Gegenstand der aktuellen Arbeiten.

Summary

An introduction to the topic was developed in a workshop in which the existing data from Energie Zukunft Schweiz (EZS) on the function control of solar thermal systems was visualised and the corresponding error patterns were explained. The inspection of a solar system where a LoRa sensor is already installed enabled the practical relevance and made the problems of solar heating systems tangible.

The existing monitoring system from EZS was copied onto a new server platform as a productive system. A second system was set up as a development system. The development system receives the mirrored data. This procedure ensures that the productive system is not endangered by the development work.

The error patterns or test cases to be detected automatically are formulated. Data from 52 systems are available, 17 of which have errors. This is a sufficient database for the project work.

The detection algorithms have been developed and evaluated with regard to their suitability for this task. A supervised learning "Long short-term Memory" (LSTM) algorithm is used with the help of the frameworks Tensorflow & Keras. The recognition of initial test cases has been implemented and is being tested on the existing data sets.

The finalisation of the programming and the testing of the automatic error detection are the subject of the current work.



Inhaltsverzeichnis

Zusammenfassung	3
Summary	3
1 Einleitung	5
2 Datenaufzeichnungen und Fehlerbilder.....	6
2.1 Fehler und deren Bewertung	6
2.1.1 Anwendungsfälle und Fehlerfälle	8
2.2 Begleitmassnahmen	13
3 Datenverarbeitung und Erkennungsalgorithmen.....	14
3.1 Infrastrukturbereitstellung	14
3.2 Datenaufbereitung	14
3.3 Erkennungsalgorithmus mit maschinellem Lernen.....	15
4 Projektsituation im 2020	18
5 Ausblick 2021.....	18
6 Dank	18
7 Literatur	19



1 Einleitung

Thermischen Solaranlagen (in Folge TS genannt) können ihren Beitrag zur Energiestrategie und zur Einhaltung von Richtlinien und Energiestandards nur erfüllen, wenn diese gemäss den bekannten Richtlinien geplant, installiert sind und ihre Funktion im laufenden Betrieb sichergestellt ist.

Zahlreiche Studien [1], [2], [3], [4], [5], [6] und [7] zeigen, dass die Menge der TS einen hohen Anteil unbemerkt, nicht funktionierender Anlagen aufweist. Die typischen Fehler von TS wurden in den Schlussberichten der kantonalen Qualitätsprüfungen zwischen 2013 und 2018 beschrieben. In den von EZS durchgeföhrten Qualitätsprüfungen TS wurden seit 2012 bereits 412 Anlagen mit einer vor Ort-Kontrolle überprüft. Dabei wurden 69 Anlagen (17%) identifiziert, welche ausser Funktion waren. Die häufigsten angetroffenen Mängel, welche die Anlagen ausser Funktion setzen, sind eine ungenügende Entlüftung der Solarleitung und Fehlfunktionen der Temperaturfühler [1], [2], [3], [4], [5], [6] und [7]. Es zeigt sich ausserdem, dass das Installationsgewerbe bei der Auswahl des Wärmesystems den TS bereits abgeneigt gegenübersteht und Alternativen wie PV und Wärmepumpen bevorzugt. Ein Grund hierfür könnte in zu vielen negativen Erfahrungen bei Inbetriebnahme und häufigen Betriebsproblemen, insbesondere bei Mehrfamilienhäusern (MFH), liegen. Die Fehlererkennung bei TS gestaltet sich für den Installateur aufgrund der örtlichen Komplexität und dem Fehlen von Analyseverfahren jedes Mal aufs Neue zu einer Herausforderung. Aufwändige Wärmemengenmessungen geben zwar Auskunft über den Ertrag. Eine Fehlfunktion wird aber dadurch zu spät erkannt, da die Messdaten zuerst ausgewertet werden müssten. Ausserdem kann damit keine ungewollte Nachtauskühlung erkannt werden und die Installation der Messgeräte ist zu teuer.

Nicht funktionierende TS werden gerade im MFH aufgrund des bivalenten Betriebs mit anderen Wärmequellen oft nicht erkannt und können somit keinen Beitrag zur Einhaltung der energetischen Grenzwerte leisten, wie sie in der MuKE 2014 und Minergie gefordert werden. Weil der Vermieter die Heizkosten an den Mieter weitergeben kann, besteht für ihn auch keine wirkliche Motivation, nicht funktionierende Solaranlagen reparieren und wieder in Betrieb nehmen zu lassen. Das heisst, die fehlende Wärmemenge, welche nicht von der TS kommt, wird über die Heizung (Wärmepumpe, Ölheizung, Fernwärme) gedeckt und an die Mieter verrechnet, ohne dass der Vermieter einen Anreiz zur Handlung hat.

Als Resultat einer vorausgegangenen Technologie-Analyse zur Prüfung von Methoden zur effizienten, flächendeckenden Funktionskontrolle solarthermischer Anlagen ergab sich die LoRaWAN-Überwachung als beste Lösung [8].

Ziel ist es, das bestehende Datensammlungssystem mit neu entwickelten selbstlernenden Algorithmen zu erweitern. Diese sollen eine automatische Überwachung von TS ermöglichen. Dies um für den Service und der Wartung von TS Möglichkeiten zur Verfügung zu stellen, welche die Fehlererkennung einfach ermöglicht und welche die Wiederinbetriebnahme sicherstellt.



2 Datenaufzeichnungen und Fehlerbilder

2.1 Fehler und deren Bewertung

Die Daten von über 500 Anlagen, welche durch EZS seit 2013 im Rahmen der Qualitätsprüfung untersucht wurden, bilden die Grundlage für die Klassifizierung der Fehler. Die möglichen Fehler wurden drei Fehlertypen zugeordnet.

Der Fehlertyp «Reduzierte Funktionsfähigkeit» umfasst alle Fehler nach Tabelle 1, bei denen Betriebsstörungen auftreten, die zu reduziertem Ertrag führen. Diese Fehler sind durch den Kunden besonders schwer zu erkennen, weil die Solaranlage immer noch Energie liefert.

Tabelle 1: Fehlertyp: Reduzierte Funktionsfähigkeit

Fehlertyp - Reduzierte Funktionsfähigkeit	Relevanz ¹ in %
Speicherfühler mit Kollektorfühler vertauscht	100
Kollektorfeldanschlüsse vertauscht	50
Ungleichmässige Felddurchströmung + partielle Kollektorstagnation	Wunsch
Falsche Kollektorfühlerposition mit vorzeitiger Stagnation / Fühlerbefestigung am Absorber abgerissen	100
Schlechte Speicherbewirtschaftung mit vorzeitiger Stagnation: <ul style="list-style-type: none">• ganzjährige Pufferspeicher-Durchladung• WW-Zirkulationspumpe durchmischt Solarvolumen	70

Stagnation bezeichnet den Zustand einer Solaranlage, in welchem die Bestrahlungsstärke typischerweise höher als 500 W/m² ist, aber keine Nutzleistung aus dem Kollektorfeld abgeführt wird. Die zahlreichen Ursachen von Stagnation können in zwei Klassen unterteilt werden, die reguläre und die fehlerbedingte Stagnation. Sobald die Speichertemperatur die zulässige Maximaltemperatur erreicht hat, schaltet der Regler die Solarkreispumpe aus, und die reguläre Stagnation beginnt. Stromausfall ist eine weitere Ursache für reguläre Stagnation. Eine Solaranlage muss Stagnation grundsätzlich ohne Schaden überstehen. Bei der regulären Stagnation handelt es sich nicht um einen Fehler, sondern um einen zulässigen Zustand. Die fehlerbedingte Stagnation kann nach Tabelle 2 viele Ursachen haben. Stagnation, die durch ein überdimensioniertes Kollektorfeld oder durch zu geringe oder fehlende Abnahme der Solarwärme bedingt ist, wird ebenfalls zur fehlerbedingten Stagnation gezählt, auch wenn die Solaranlage fehlerfrei aufgebaut und geregt wird.

Tabelle 2: Fehlertyp: Stagnation

Fehlertyp - Stagnation	Relevanz in %
Stillstand auf Grund Leckage	100
Stillstand mit Luft im Solarkreis	100
Zu kleines MAG führte zu Stillstand	20
Fühlerkabeldefekt (Vogelfrass, Korrosion)	100
Solaranlage nicht eingeschaltet	100

Der Fehlertyp Nachtauskühlung umfasst alle Störungen, bei der Wärme aus dem Speicher über das Kollektorfeld an die Umgebung fliesst. Zwar könnte auch die Nachtauskühlung dem Fehlertyp «reduzierte Funktionsfähigkeit» zugeordnet werden. Aufgrund seiner Bedeutung und dem

¹ Die Relevanz wurde qualitativ festgelegt in anbetracht von: der resultierenden Ertragseinbusse, der Häufigkeit im Auftreten in der Praxis und der Detektierbarkeit mittels der hier verfolgten Methodik.



charakteristischen Fehlerbild wird dieser Typ als eigene Klasse geführt. Tabelle 3 zeigt die wichtigsten Ursachen dieses Fehlertyps.

Tabelle 3: Fehlertyp: Nachtauskühlung

Fehlertyp - Nachtauskühlung	Relevanz in %
Offener oder nicht dicht schliessender Rückflussverhinderer	100
Rückflussverhinderer mit zu geringem Öffnungsdruck	
Defekter Kollektorfühler zeigt zu hohe Temperatur	100
Speicherfühler herausgerutscht oder nicht am Speicher	100
Handbetrieb eingestellt am Regler	100

Jeder Fehler wurde mit Hilfe einer «Failure Mode and Effects Analysis» (FMEA) bewertet. Nebst der betriebstechnischen Auswirkung und der Wichtigkeit des Fehlers wurden auch die Möglichkeiten der Fehlererkennung anhand von Temperaturverläufen ermittelt. Tabelle 4 zeigt einen Ausschnitt des Resultats der FMEA. Die Erkennungsmerkmale bilden die Grundlage für die Entwicklung der Algorithmen.

Tabelle 4: Auszug aus der Fehlerbild-Erkennung mittels FMEA-Ansatz.

Fehlertyp	Wirkung	Erkennung		Relevanz in %
Speicherfühler mit Kollektorfühler vertauscht	Solarkreis nachtaktiv + bei Schlechtwetter	Betrieb in der Nacht und nicht am Tag.		100
Kollektorfeldanschlüsse vertauscht	Takten Vorzeitige Stagnation	Viele Unterbrüche im T_VL Verlauf	 Siehe: VL_RL_Vertauscht.vi2	50

Aktuell sind 52 Anlagen in der Überwachung der EZS und liefern wertvolle Daten für die Erarbeitung der Algorithmen durch die FHNW. Bei den Solaranlagen handelt es sich durchwegs um Warmwasser-Vorwärmmanlagen im MFH von unterschiedlichen Installateuren. Ein regelmässiger Datentransfer unter Berücksichtigung der Anonymisierung der Daten von der EZS an die FHNW findet statt. Von den insgesamt 52 Anlagen weisen 17 Anlagen Fehlfunktionen auf, die für die Erarbeitung der Algorithmen genutzt werden. Die Anlagen ohne Fehlfunktion dienen als Referenz für ein normales Anlageverhalten.

Im Folgenden werden die wichtigsten Anwendungen und Fehlerzustände, wie sie im LoRa-Monitoring der EZS an realen TS aufgezeichnet wurden dokumentiert. Es werden Ausschnitte von jeweils drei Tagen gezeigt. In diesem Zeitfenster ist die gemessene Vorlauftemperatur des Solarkreises und die aus Wetterdaten gewonnene Information zur aktuellen Außentemperatur und die Globalstrahlung aufgezeigt. Diese Anwendungsfälle und Fehlerzustände dienen der Erarbeitung der Algorithmen an der FHNW.



2.1.1 Anwendungsfälle und Fehlerfälle

Erkennen der Montage-Position des Temperatursensors

Erfahrungen mit der Konnektivität des LoRaWAN-Netzes von Swisscom innerhalb des bestehenden LoRa-Monitorings der EZS zeigen, dass auch im Heizungskeller in nahezu allen Fällen eine Funkverbindung aufgebaut werden kann. Bei der Erarbeitung der Algorithmen wird deshalb eine weitere Klassifizierung, die Position des Fühlers (Im Heizungskeller oder auf dem Dach am Sonnenkollektor) eingeführt. Eine Stagnation bei einer Solaranlage zeigt je nach Position des Temperaturfühlers einen anderen Temperaturverlauf. Diese sind in Abbildung 1 und Abbildung 2 dargestellt.

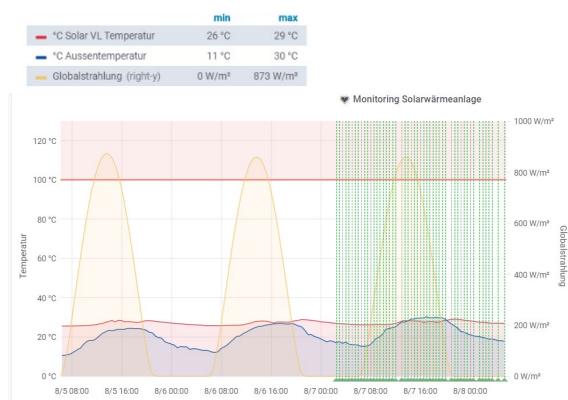
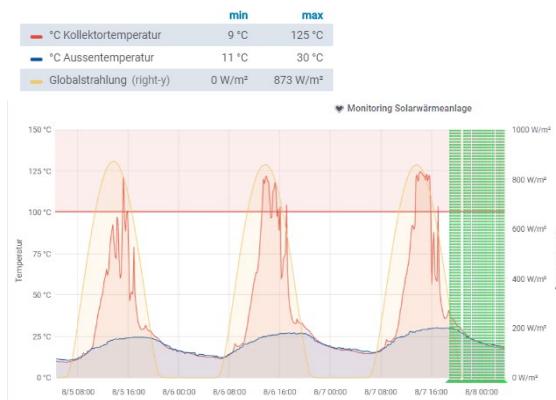


Abbildung 1: Stagnation einer TS mit Temperaturen über 100°C, gemessen am Kollektoraustritt. (Die grünen Stiche verdeutlichen eingehenden Messpunkte und dienen zur Erkennung von Messlücken).

Abbildung 2: Stagnation der selben Anlage wie in Abbildung 1, zusätzlich gemessen am Solar-Vorlauf im Heizungskeller.

Nachtauskühlung

Die Herausforderung liegt hier im Erkennen der Nachtauskühlung und der Unterscheidung zwischen einem normalen Anlagezustand bei der Installation des LoRa-Sensors am Vorlauf des Kollektorfeldes dem Dach oder im Heizungskeller.

Zur Unterscheidung einer langsamen Abkühlung auf Grund Restwärme im Kollektor, insbesondere bei Vakuumröhrenkollektoren ist die Installation des LoRa-Sensors in mindestens 1 m Abstand nach dem Austritt aus dem Kollektor vorzusehen. Die Abbildung 4 zeigt einen typischen Verlauf der Vorlauftemperatur im Solarkreis mit Nachtauskühlung.



Abbildung 3: Anlage Nr. 4045 mit nachweislicher Nachtauskühlung einer Flachkollektor-Anlage.

Der Fall einer Nachtauskühlung bei der Installation des LoRa- Sensors im Heizungskeller liegt aktuell noch nicht vor, sodass daraus Algorithmen generiert werden können. Als nächster Schritt ist vorgesehen einen LoRa-Sensor bei einer bekannten Solaranlage in den kommenden Wochen im Heizungskeller einzubauen und eine Nachtauskühlung durch den Handbetrieb der Solarpumpe zu erzwingen. Die Sensortemperatur muss sich dann parallel zur Aussentemperatur verhalten.

Stagnation

Eine Stagnation kann hauptsächlich zwei Ursachen haben. Erstens kann eine Stagnation Aufgrund eines normalen Anlageverhaltens entstehen, wie z.B. im Sommer nach einer maximalen Speicherbeladung wie in Abbildung 4 dargestellt. Zweitens kann eine Stagnation Aufgrund eines Anlagenfehlers entstehen, wie in Abbildung 5 gezeigt (Luft im System, defekter Temperaturfühler...).

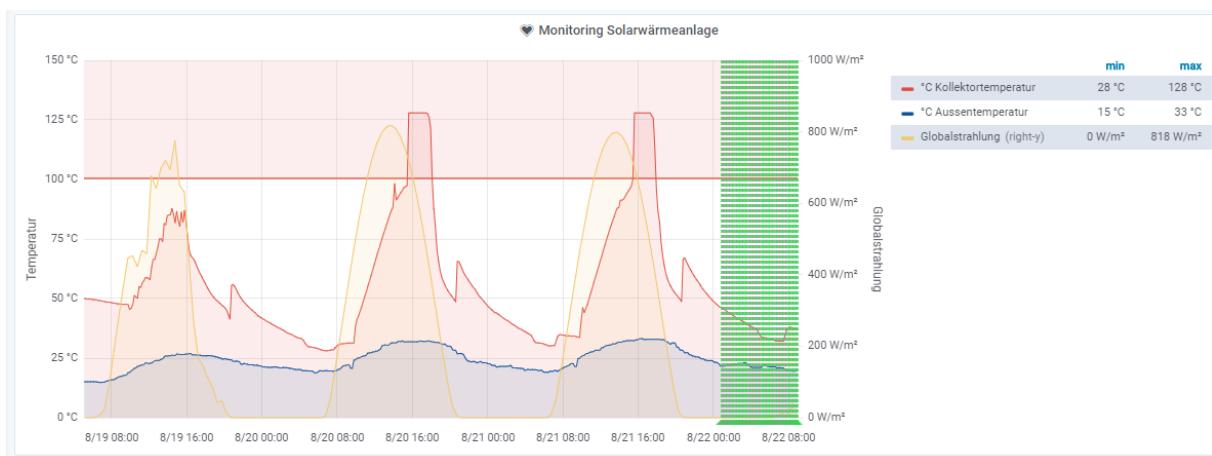


Abbildung 4: Anlage Nr. 4042 zeigt eine Stagnation auf Grund zu geringem Verbrauch, bzw. einer Überdimensionierung der TS. Die Rückkühlung des Speichers über den Sonnenkollektor wurde bereits aktiviert und ist im nächtlichen Anstieg der LoRa-Sensortemperatur (Kollektortemperatur) zu erkennen.



Abbildung 5: Anlage Nr. 4053 geht nach zwei Tage ohne erhebliche Einstrahlung (< 200W/m²) am dritten Tag mit Einstrahlung (>500W/m²) unmittelbar in Stagnation. Damit kann gezeigt werden, dass die Stagnation nicht auf Grund maximaler Speicherbeladung sondern auf Grund eines Anlagefehlers verursacht wurde.

Speicherbewirtschaftung und Dimensionierung

Wichtige Optimierungsindikatoren sind das Erkennen der maximalen Speichertemperatur vor und nach einer solaren Speicherbeladung. Da Solarregler häufig mit einer voreingestellten Speichertemperaturbegrenzung von 60 °C ausgeliefert werden und diese nicht durch den Installateur z.B. auf 85°C (trotz Installation eines Thermomischers) erhöht wird kommt es zu einer ineffizienten Speicherkapazitätsnutzung.

Zusätzlich kann mit diesen Optimierungsindikatoren auch eine häufig auftretende Durchmischung des Solarvolumens über die Backup-Wärmequelle (falsch angeschlossene WW-Zirkulationsleitung, Schwerkraftzirkulation...) erkannt und eine Ertragsabschätzung erstellt werden.

In Abbildung 6 kann aus der Abflachung der Steigung der Vorlauftemperaturkurve erkannt werden, auf welchem Temperaturniveau sich der Solarspeicher vor dem Pumpenstart befunden hat. Wie man aus der Abbildung erkennen kann, geht die Anlage am zweiten oder dritten Tag danach in Stagnation bei einer erreichten Kollektortemperatur von 95°C. Die Speichermaximalbegrenzung im Solarregler hat demnach die Anlage vorzeitig gestoppt.

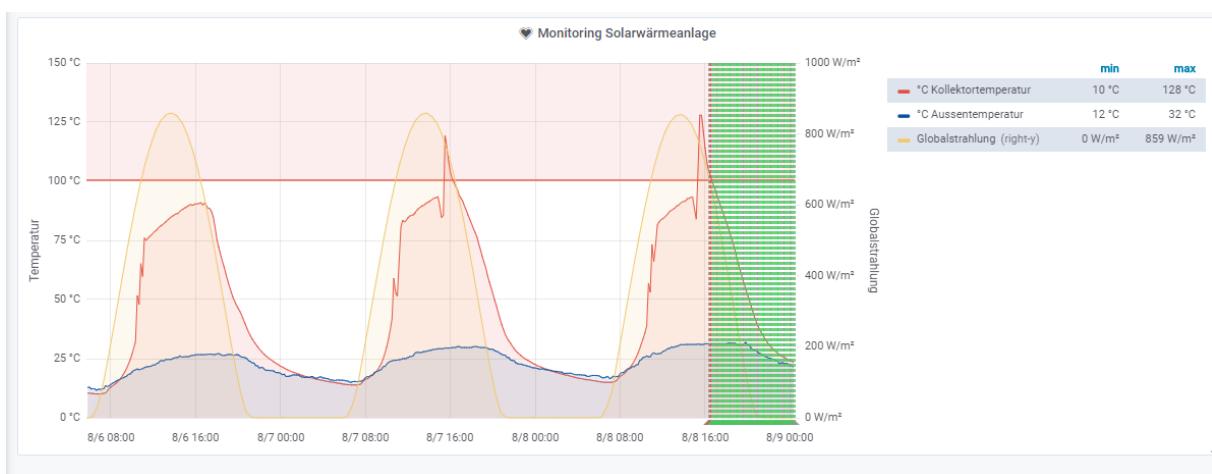


Abbildung 6: Typischer Verlauf einer solaren Speicherbeladung, erkannt am Verlauf der Solar-Vorlauftemperatur.



Leitungsvertausch bei der Installation

Das Anlageverhalten bei vertauschtem Vor- und Rücklauf im Solarkreis ist charakterisiert durch ein Taktieren in der Anlagefunktion. Bisher konnte dieses Verhalten nur bei einer Anlage ausserhalb des LoRa-Monitorings mit konventioneller Messtechnik erfasst werden und ist in der Abbildung 7 zu erkennen.

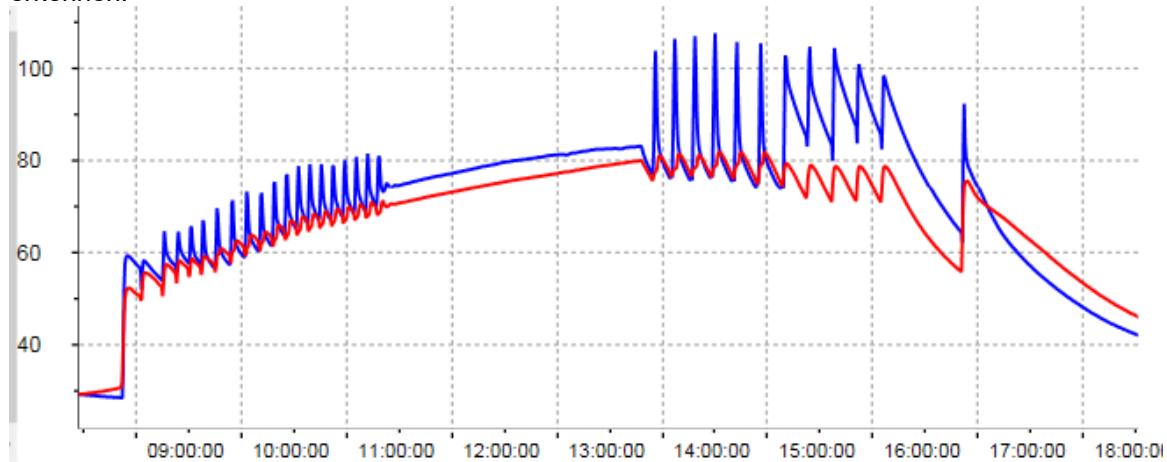


Abbildung 7: Typisches Takt-Verhalten des Vorlaufs (blau) und des Rücklaufs (rot) bei einer TS bei der die Anschlüsse vertauscht wurden.

Orientierung des Kollektorfelds

Die Orientierung der Solarkollektoren kann durch den Versatz der gemessenen Vorlauftemperatur im Solarkreis und der überlagerten Globalstrahlung erkannt werden. Die Abbildung 8 und Abbildung 9 zeigen den Verlauf der Vorlauftemperatur von jeweils einer Anlage mit West- bzw. Ostorientierung.

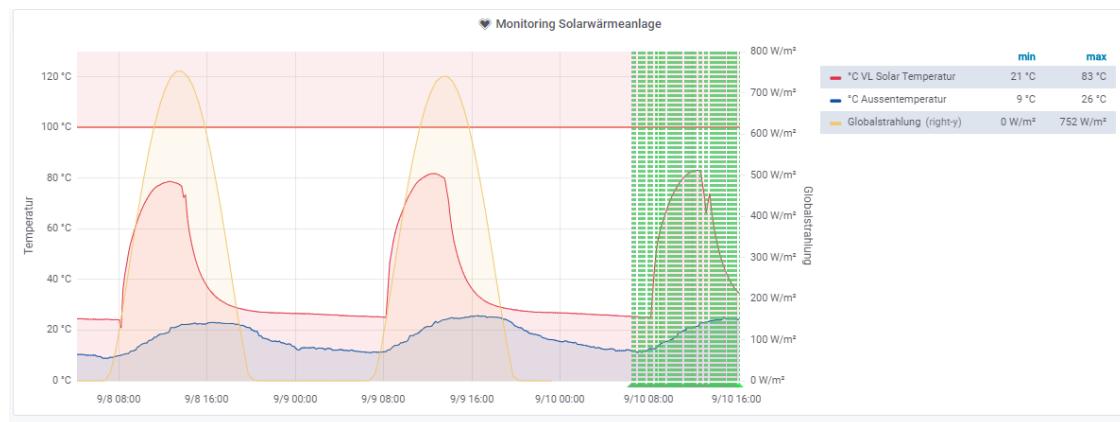


Abbildung 8: Anlage Nr. 9262 mit Ostorientierung.

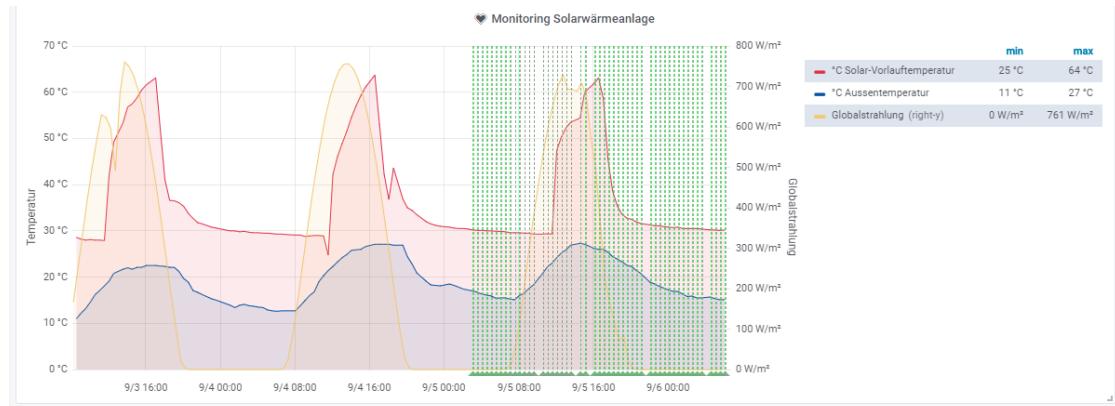


Abbildung 9: Anlage Nr. 9264 mit West-Orientierung.

Im Herbst 2020 konnte mit dem LoRa-Monitoring der EZS bei einer sonst gut funktionierenden Solaranlage erstmalig einen Fehler detektieren (Abbildung 10), der an den Installateur weitergegeben wurde. Alle anderen bisherigen Fehler waren bei Anlagen von denen bereits eine Fehlfunktion bekannt war bzw. vermutet wurde. Die Fehlererkennung geschah noch auf Basis der einfachen, von EZS programmierten logischen Algorithmen.



Abbildung 10: Automatische Fehlererkennung einer realen Anlagestörung im Herbst 2020.

Die wichtigsten Fehlerbilder sind dokumentiert. Im Laufe des kommenden Jahres werden Fehlerbilder analysiert welche bisher noch nicht erklärbar sind. Außerdem wird die automatische Erkennung der Fühlerposition eine weitere Herausforderung darstellen, sowie die Fehlererkennung unter Berücksichtigung dieser unterschiedlichen Fühlerposition (am Kollektor im Freien / unter dem Dach / im Heizungskeller).



2.2 Begleitmassnahmen

Die EZS bewirbt das LoRa-Monitoring bereits intensiv mit dem eigenen Produkt LORALARM, welches auch auf der Homepage loralarm.ch vorgestellt wird. Wie bereits im Projektantrag angekündigt, fördert der Gasverband Mittelland (GVM) jetzt das von EZS angebotene LoRa-Monitoring von TS auch im Bestand, sofern die TS zusammen mit einem Gaskessel installiert wurde und wenn die TS im Versorgungsgebiet der GVM liegt. Ein Hersteller von TS und drei Installateure aus der Region Basel nutzen das LORALARM für TS bei Kunden bereits. Dies vorwiegend bei den Kunden bei denen ein Servicevertrag besteht. Die Installation des LoRa-Sensors beim anstehenden vor-Ort-Service Besuch der TS verursacht somit keinen Mehraufwand und bringt einen deutlichen Mehrwert für den Fachmann und den Kunden.

Das LoRa-Monitoring für TS wurde durch EZS erstmals am 20.Okttober 2020 an einer suissetec – Abendveranstaltung deren Mitgliedern in der Region Basel vorgestellt. Die 9. Tagung Solarwärme Schweiz in Hedingen ist leider ausgefallen. Es kann aber dennoch eine steigende Nachfrage verzeichnet werden. Aktuell werden 52 Anlagen mit LORALARM überwacht. Wir rechnen für das Jahr 2021 weitere 100 Anlagen die in das LOARLARAM – Monitoring aufgenommen werden sollen. Aktuell ist ein Projekt in der Vorbereitung zusammen mit dem Verband der Wohnbaugenossenschaften NWCH, um alle Solaranlagen bei Wohnbaugenossenschaften im Raum Basel mit LORALARM auszustatten. Die Partnerfirmen sind aktiv dabei die Solaranlagen, welche aktuell mit einem Servicevertrag betreut werden mit LORALARM auszustatten.

Deshalb ist die Automatisierung der Fehlererkennung über die hier zu erarbeitenden Algorithmen für EZS sehr wichtig.



3 Datenverarbeitung und Erkennungsalgorithmen

3.1 Infrastrukturbereitstellung

Der Test-Server / FHNW Datawarehouse wurde bei der FHNW mit gleicher und ähnlicher Technologie als der Produktiv-Server aufgesetzt. Jedoch wurden wesentliche Elemente für die Verwaltung und automatische Datenverarbeitung ergänzt (Abbildung 11). Es wird ein Datawarehouse² Ansatz verfolgt. Dieser genügt den bestehenden Anforderungen an die zu leisteten Aufgaben und die Weiterentwicklung der zu erfassenden Anlagen. Die Server wurde so gewählt, dass die vom Produktivsystem kopierten Daten auf eine technologisch identische Datenbank (Influx DB) übertragen werden können. Eine weitere Datenbank wurde erstellt, welche die Analgendaten beinhaltet (PostgreSQL).

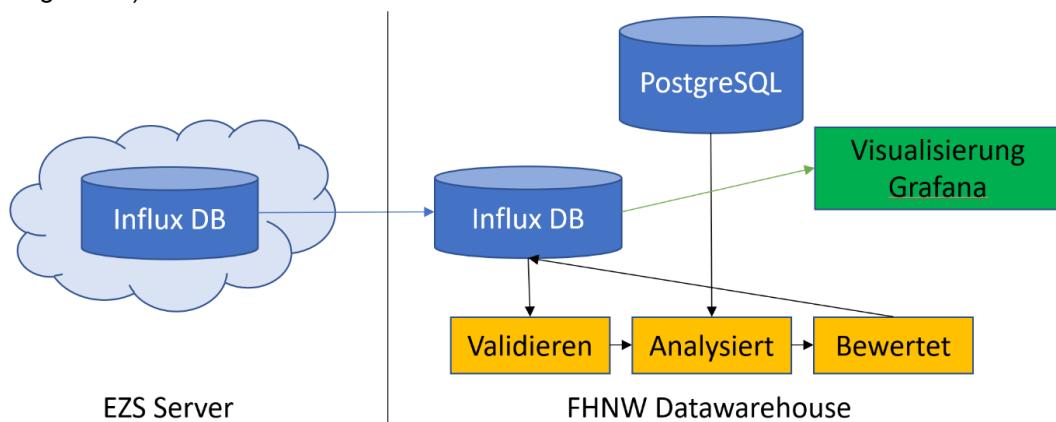


Abbildung 11: Server-Topologie

3.2 Datenaufbereitung

Die Sensordaten (Abbildung 12 in blau hinterlegt) durchlaufen einen mehrstufigen Prozess: Validieren, Analysieren und Bewerten. Das Resultat ist die Anreicherung der Sensordaten mit Auswertungs-Informationen (in Abbildung 12: grün hinterlegt), wie Tageswerte, Sonnenverlauf, erkannte Fehlerbilder etc. Diese werden als Zeitreihe abgelegt und können grafisch dargestellt werden.

Anlage	Datengruppe	Datenspuren	Daten						
Anlage XYZ	Sensor Daten:								
		Temperatur	Wert	Wert	Wert	Wert	Wert	Wert	Wert
		Batterieladung	Wert	Wert	Wert	Wert	Wert	Wert	Wert
		Wetterdaten	Wert	Wert	Wert	Wert	Wert	Wert	Wert
	Logik Daten:	Daten valide	Wert	Wert	Wert	Wert	Wert	Wert	Wert
		Sonnengang	Wert	Wert	Wert	Wert	Wert	Wert	Wert
		Stagnation	Wert	Wert	Wert	Wert	Wert	Wert	Wert

Abbildung 12: Datenspuren

² Ein Data Warehouse (DWH) ist ein zentraler Speicher für Daten, die aus einer oder mehreren Datenquellen gesammelt werden. Mit Hilfe von DWH ist es möglich, Daten zu verwalten und schnelle Analysen auf großen Datenmengen durchzuführen und so versteckte Muster aufzudecken. [9]



3.3 Erkennungsalgorithmus mit maschinellem Lernen

Die Bearbeitung von Problemen mit Hilfe des maschinellen Lernens, insbesondere des «Deep Learnings» lässt sich in mehrere Prozessschritte gliedern (siehe Tabelle 5):

Tabelle 5: Prozessschritte und Stand der Entwicklungen beim maschinellen Lernen

Item	Prozessschritt	Status
1	Welche Algorithmen eignen sich für die Anwendung	erledigt
2	Welche Eigenschaften haben die Algorithmen	erledigt
3	Abschätzung der anfallenden Datenmenge und Entscheid supervised oder unsupervised learning.	erledigt
4	Festlegen der Testfälle (Features)	erledigt
5	Programmieren der Rücklese und erneute Bearbeitung der Daten für die Feature Extraktion.	erledigt
6	Programmieren der Feature Extraktion	erledigt
7	Programmieren des Übergabe-Formats für «Tensorflow»	erledigt
8	Training des Netzwerkes mit den Trainings-Daten	In Bearbeitung
9	Ergebnis-Analyse mit den Testdaten	offen
10	Optimieren des Prozesses	offen

Welche Algorithmen eignen sich für die Anwendung

In einer ersten Analyse wurde ein geeignetes Netz entsprechend der Applikation (LoCoSol) ausgewählt. Die Anwendung liefert Zeitreihen mit einer Periodizität von 24 Stunden. Folgende Neuronale Netze sind hierfür geeignet [10]:

- RNN (Recurrent Neural Networks) und
- LSTM (Long short-term Memory).

Um bestimmte Fehler zu erkennen ist es notwendig, dass der Algorithmus eine Gedächtnisfunktion hat. In unserem Fall heisst dies: Es sollte neben dem vom Algorithmus aktuell bearbeiteten Tag auch noch Information aus den letzten beiden Tagen einbezogen werden. Das neuronale Netzwerk LSTM [11] hat Gedächtnisfunktionalität, weshalb die Auswahl in diesem Projekt auf Netzwerke vom Typ LSTM fällt.

Welche Eigenschaften (Aussagen) haben diese Algorithmen

Algorithmen produzieren Aussagen zu bestimmten Fragestellungen. Die vier Klassen von Algorithmen, welche in die nähere Betrachtung einbezogen wurden sind (sie wurden mit einem Beispiel versehen):

- Vorhersagen («Forecasts») [12]: In der Gebäudeautomation werden aus den Wetterdaten, den Messdaten über den Zustand des Gebäudes und dem Gebäudemodel Prognosen (Vorhersagen) für die Steuerung des Gebäudes in den nächsten Tagen gemacht.
- Seltene Ereignisse («Rare events») [13]: Bei Maschinen (auch Wärmepumpe, FHNW) werden aus Temperaturverläufen, Schall- und Schwings-Messungen Aussagen über den Zustand der Maschine und das Auftreten von Störungen gemacht.
- Erkennung menschlicher Aktivitäten («HAR») [14]: Unter der Verwendung des Beschleunigungssensors eines Smartphones lassen sich für verschieden menschliche Bewegungsabläufe typische Zeitreihen aufzeichnen, welche dann zur Bewegungserkennung mit neuronalen Netzen verwendet werden.



- Elektrokardiogramm (EKG/«ECG») [15]: Aus den mit neuronalen Netzen erkannten Formen der Pulskurven, die für bestimmte Störungen am Herzen typisch sind, lassen sich Aussagen über den Gesundheitszustand des Patienten machen.

Bezogen auf die Aussagen hat LoCoSol die grösste Übereinstimmung mit der Klasse von Algorithmen, welche bei der Erkennung menschlicher Aktivitäten (HAR, Sitzen, liegen, stehen, laufen usw.) eingesetzt werden. Der Algorithmus soll anhand der Temperatursignale eines Sensors, der an einer geeigneten Stelle in der Anlage eingebaut ist, Fehler erkennen. Da die Messdaten bei LoCoSol eine zeitperiodische (Tag/Nacht) Struktur haben, besteht zusätzlich eine grosse Übereinstimmung zum EKG. Die Periodizität entsteht durch die Auswahl des Beobachtungsfensters für den Algorithmus. Es wird zum Beispiel ein Tag beobachtet. Mit 6 Abtastwerte pro Stunde erhält man 144 Abtastwerte pro Tag.

Abschätzung der Datenmenge und der Entscheid «supervised» oder «unsupervised»

Lernalgorithmen von neuronalen Netzen können «supervised» und «unsupervised» sein [16]:

- Bei «supervised-learning» werden bestehende Datensätze mit dem «Feature»/Fehlerbild betitelt, was von Hand (durch den Menschen) oder mit einem Auswahl-Programm geschehen kann. Bei LoCoSol werden Tageskurven so betitelt, dass das neuronale Netz gezielt trainiert werden kann und diese wieder findet.
- Bei «unsupervised-learning» werden die Datensätze ohne Zusatzinformationen dem neuronalen Netz übergeben. Das Netzwerk versucht, in den Daten Muster, Gruppen und Gemeinsamkeiten zu identifizieren. Das Ergebnis ist vorher nicht bekannt. Ein Beispiel hierfür ist die Anwendung des Autoenkoder in [15].

Aus dem Vergleich der Anzahl zur Verfügung stehenden Zyklen in den Messdaten von LoCoSol mit den Anwendungen in [13] [14] lässt sich schliessen, dass die zu Verfügung stehende Datenmenge für ein «unsupervised-learning» nicht ausreichend ist, sehr wohl aber für «supervised-learning».

Die Zusammenfassung dieser Überlegungen führen dazu, ein «supervised-learning» LSTM unter der Zuhilfenahme von dem im Bereich Data-Science bekannten «Framework» Tensorflow & Keras [17] zum Einsatz zu bringen.

Tensorflow ist ein «Framework» zur datenstromorientierten Programmierung. Populäre Anwendung findet TensorFlow im Bereich des maschinellen Lernens. Es wird benutzt um Modelle für das maschinelle Lernen zu entwickeln. Keras bietet eine einheitliche Benutzer-Schnittstelle für verschiedene Backends, darunter TensorFlow.

Festlegen der Testfälle (Features)

Um das LSTM supervised zu trainieren, ist es erforderlich ein Test & Trainings -Daten-Set aus «Features» zur Verfügung zu haben.

Die «Features» (Strukturen in den Messdaten, welche für spezielle Ereignisse stehen bzw. die in Kapitel 2.1.1 genannten Fehlertypen) wurden gemeinsam mit den Fachspezialisten für Solarkollektoren festgelegt.

Programmieren des Rückleseprozesses zur erneuten Bearbeitung der Daten

In dieser Stufe wurden die Analyse- und Auswerte-Programme, mit welchem die vorhandenen Messdaten zurückgelesen und erneut bearbeitet/analysiert werden, implementiert.

Programmieren der «Feature»-Extraktion

In dieser Stufe wurden logische Software-Algorithmen geschrieben, welche nach diesen Strukturen in den Messdaten suchen, um daraus Trainings- & Test-Daten zu erzeugen. Die Auswertung erfolgt mit den «Key Performance Indicators» (KPI) welcher einem «Feature» spezifisch zugeordnet ist.



Tabelle 6: Daten-Beispiele aus der Feature-Extraktion :

Zeit	DeVName	kpi1	kpi_desc	kpi_id
2019-02-06T08:57:00Z	Sensor Nr. SX237	27.9	Pumpe eingeschaltet bei Kollektortemperatur von 27.9°C	5
2019-02-06T09:09:00Z	Sensor Nr. SX234	48.8	Pumpe eingeschaltet bei Kollektortemperatur von 48.8°C	5

Programmieren des Übergabeformates an Tensorflow

Die so extrahierten Daten wurden in ein Format gepackt, welches von «Tensorflow» unterstützt wird. Bei der Übergabe der Messdaten an «Tensorflow» haben sich in unseren Messdaten zwei Probleme gezeigt, welche korrigiert werden mussten.

1. Die Datensammlung weist einen Datenverlust (fehlende Werte in einer Zeitreihe) auf. In der Abbildung 13 unten sind die Lücken in den empfangenen Roh-Daten zu sehen. Da der Algorithmus darauf angewiesen ist, dass ein Tag genau mit 144 Abtastwerten abgebildet wird, wurde eine Software geschrieben, welche diese Lücken in den Zeitreihen durch Interpolation korrigiert. In der Abbildung 14 unten sind 10 korrigierte Tage mit einer Länge von 144 Abtastwerten übereinander dargestellt.



Abbildung 13: Beispiel der Kollektor-Temperatur mit Funklücken

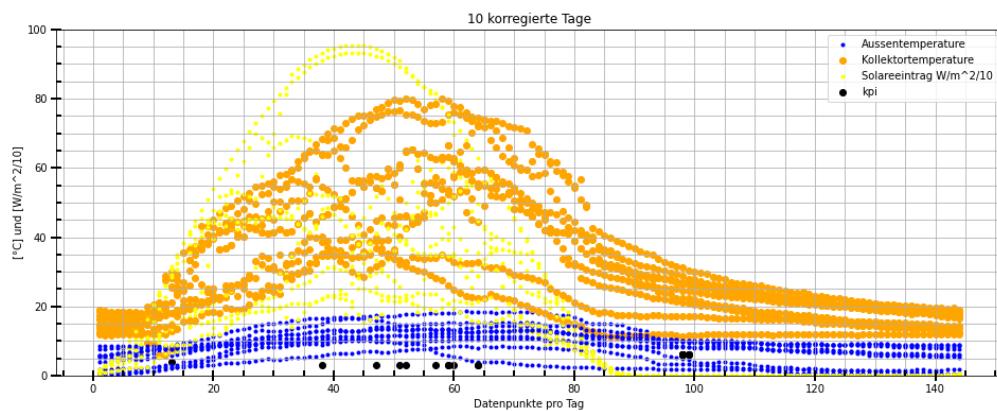


Abbildung 14: Beispiel der auf Funklücken korrigierten Messdaten



2. Die Menge der Abtastungen im gewählten Beobachtungszeitraum von knapp einem $\frac{3}{4}$ Jahr eines Sensors im Raum Basel ist nicht ausreichen für das Daten-Set von Trainings- und Test-Daten. Deshalb werden in der Vorbereitung aus den Messdaten der Sensoren, Sensoren in einem Beobachtungsfenster mit exakt gleichem Anfangs- und Enddatum, sowie exakt der gleichen Anzahl von Abtastwerten ausgewählt. Diese werden in einer Zeitreihe hintereinandergestellt, damit lässt sich die für den Algorithmus erforderliche Datenmenge geschaffen. Die so formatierten Daten werden dem «Tensorflow» übergeben.

4 Projektsituation im 2020

Das Projekt wurde im November 2019 gestartet. Zwei Workshops der Forschungspartner bildeten den Grundstein für die ersten Tätigkeiten, siehe Jahresbericht von 2019. Im ersten Halbjahr vom Jahr 2020, wurde an der Konkretisierung der Testfälle, dem Aufsetzen des Testsystems und implementieren der Testalgorithmen gearbeitet.

Der Austausch und die Koordination unter den Forschungspartnern wurde durch den «Lockdown» wegen COVID-19 erschwert. Des Weiteren waren Dienstleister (IT-Services) wegen der selben Ursache anderweitig gebunden, weswegen der Projektfortschritt etwas verzögert ist.

5 Ausblick 2021

Anfang 2021 wird das Training der Neuronalen Netze abgeschlossen sein. Anschliessend erfolgt der Test und der Erprobung an weiteren Testdaten in der «offline» Umgebung.

Ist das neuronale Netz trainiert, wird dieses Programmpaket in die Software der Firma EZS parallel zur bestehenden Software integriert und es lassen sich im Feld Vergleichsmessungen zur bestehenden Lösung anstellen.

6 Dank

Die Autoren danken Dr. Elimar Frank für das Interesse an dieser Arbeit, sowie dem Bundesamt für Energie für die Forschungsmittel.



7 Literatur

- [1] Bernd Sitzmann, «Qualitätsprüfung thermische Solaranlagen 2013 Schlussbericht», Energie Zukunft Schweiz, Basel, Okt. 2013.
- [2] Bernd Sitzmann, «Qualitätsprüfung thermische Solaranlagen 2014 Schlussbericht», Energie Zukunft Schweiz, Basel, Sep. 2014. [Online]. Verfügbar unter: [@download/file/qualitaetspruefung-therm-solaranlagen_2014.pdf](https://www.basel.ch/politik-und-behorden/direktionen/bau-und-umweltschutzzdirektion/umweltschutz-energie/energie/publikationen/downloads/qualitaetspruefung-therm-solaranlagen_2014.pdf).
- [3] Bernd Sitzmann, «Qualitätsprüfung thermische Solaranlagen 2015 Schlussbericht», Energie Zukunft Schweiz, Basel, Sep. 2015. [Online]. Verfügbar unter: https://energiezukunfts Schweiz.ch/wAssets/docs/qs/qualitaetspruefung_therm_solaranlagen_2015.pdf.
- [4] Bernd Sitzmann, «Qualitätsprüfung thermische Solaranlagen 2018 Kantone Basel-Stadt und Basel-Landschaft», Energie Zukunft Schweiz, Basel, Nov. 2018. [Online]. Verfügbar unter: <https://www.aue.bs.ch/dam/jcr:35a706c2-4e19-4e42-b4ac-6421ce945c45/Qualitaetspruefung-thermische-Solaranlagen-BS-BL-20181127-Schlussbericht.pdf>.
- [5] Bernd Sitzmann, «Qualitätsprüfung thermische Solaranlagen 2019 Kanton Basel-Stadt», Energie Zukunft Schweiz, Basel, Dez. 2019. [Online]. Verfügbar unter: https://energiezukunfts Schweiz.ch/wAssets/docs/qs/20191216_schlussberichtqssolarbs2019.pdf.
- [6] Bernd Sitzmann, «Qualitätssicherung Förderprogramm „Sonnenkollektoren für Warmwasser und Heizungsunterstützung“», Kanton Solothurn, Amt für Wirtschaft und Arbeit, Basel, Juni 2014. [Online]. Verfügbar unter: https://energiezukunfts Schweiz.ch/wAssets/docs/qs/Qualitaetssicherung_Foerderprogramm__Sonnenkollektoren.pdf.
- [7] Bernd Sitzmann, «Ergebnisse aus der Qualitätsprüfung thermische Solaranlagen in der Region Basel», in 24. Symposium Thermische Solarenergie, Bad Staffelstein, Mai 2014, Bd. 24.
- [8] Bernd Sitzmann, «Prüfung von Methoden zur effizienten, flächendeckenden Funktionskontrolle solarthermischer Anlagen», Bundesamt für Energie BFE, Basel, Feb. 2017. [Online]. Verfügbar unter: <https://pubdb.bfe.admin.ch/de/publication/download/8816>.
- [9] F. Weber, *Künstliche Intelligenz für Business Analytics: Algorithmen, Plattformen und Anwendungsszenarien*. Springer Vieweg, 2020.
- [10] S. Abbaspour, F. Fotouhi, A. Sedaghatbaf, H. Fotouhi, M. Vahabi, und M. Linden, «A Comparative Analysis of Hybrid Deep Learning Models for Human Activity Recognition», *Sensors*, Bd. 20, Nr. 19, Art. Nr. 19, Jan. 2020, doi: 10.3390/s20195707.
- [11] S. Hochreiter und J. Schmidhuber, «Long Short-Term Memory», *Neural Computation*, Bd. 9, Nr. 8, S. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [12] B. Jeon und E.-J. Kim, «Next-Day Prediction of Hourly Solar Irradiance Using Local Weather Forecasts and LSTM Trained with Non-Local Data», *Energies*, Bd. 13, Nr. 20, Art. Nr. 20, Jan. 2020, doi: 10.3390/en13205258.
- [13] P. Park, P. D. Marco, H. Shin, und J. Bang, «Fault Detection and Diagnosis Using Combined Autoencoder and Long Short-Term Memory Network», *Sensors*, Bd. 19, Nr. 21, Art. Nr. 21, Jan. 2019, doi: 10.3390/s19214612.
- [14] Jason Brownlee, «How to Model Human Activity From Smartphone Data», Sep. 17, 2018. <https://machinelearningmastery.com/how-to-model-human-activity-from-smartphone-data/>.
- [15] Venelin Valkov, «Time Series Anomaly Detection using LSTM Autoencoders with PyTorch in Python», März 22, 2020. <https://curiously.com/posts/time-series-anomaly-detection-using-lstm-autoencoder-with-pytorch-in-python/>.
- [16] Jason Brownlee, «How to Model Human Activity From Smartphone Data, Update», Aug. 05, 2019. <https://machinelearningmastery.com/how-to-model-human-activity-from-smartphone-data/>.
- [17] Jeff Hale, «Deep Learning Framework Power Scores 2018», 2018. <https://www.kdnuggets.com/2018/09/deep-learning-framework-power-scores-2018.html>.