

Abschlussbericht zum Vorhaben

HortiSem und Hortisem-vertical

Vorhabenbezeichnung:

Verbundprojekt: Aggregation von Informationen zum Pflanzenschutzinsatz im Gartenbau (HortiSem) – Teilvorhaben 5 - mit Weiterentwicklung im Rahmen der Förderung von Projekten zum Vertical Farming (Aufstockungsantrag Hortisem-vertical)

Zuwendungsempfänger:

Julius Kühn-Institut,
Bundesforschungsinstitut für Kulturpflanzen

Förderkennzeichen:

2818508E18

Laufzeit des Vorhabens:

15.12.2019 bis 31.12.2023 (geänderte Laufzeit infolge des Aufstockungsantrags Hortisem-vertical)

Kleinmachnow, 15.07.2024

Teil I Kurzbericht

I.1 Aufgabenstellung

Die Anforderungen an die gartenbauliche Beratung und Praxis hinsichtlich des Pflanzenschutzes sind in den Jahren immer komplexer geworden. Die heterogenen Strukturen des Gartenbaus mit einer Vielzahl verschiedener Kulturen und eine Nutzung aller im Pflanzenschutzrecht verankerten Sonderregelungen für Kleinkulturen und Notfallzulassungen stellen für die Akteure hinsichtlich der Datenbeschaffung und Verarbeitung eine besonders große Herausforderung dar. Für die Umsetzung der an den Pflanzenschutz geknüpften rechtlichen Vorgaben benötigen die Akteure einen einfachen und schnellen Handlungsweg, um an die entscheidenden Informationen zu gelangen.

Dieser Handlungsweg sollte mit sowohl menschen- als auch maschinenlesbaren Daten beschrieben werden. Idealerweise sollten die zugrundeliegenden Datenbanken sowohl regional, bundesweit als auch europaweit zuverlässig und rechtssicher miteinander interagieren, beispielsweise über Linked-Data-Prinzipien. Allerdings fungieren die bisher entwickelten Informationssysteme wie die Online-Datenbank des BVL, PS Info, ISIP, hortigate u.a. derzeit als Einzelsysteme und stellen in der Gesamtbetrachtung Insellösungen dar.

Aufgabe und Ziel des Verbundvorhabens war die Demonstration praxisorientierter und funktionierender Linked-Data-Prinzipien am Beispiel der Beantwortung gartenbaulicher Praxisfragen zum Thema Pflanzenschutz.

Das gut eingeführte und breit genutzte System PS Info, welches in der aktuellen Form die Zulassungsdaten des BVL darstellt, soll gartenbauliche Fragestellungen besser bedienen können und als Anwendungsbeispiel für die Nutzung von Linked-Data-Prinzipien dienen. Das System soll bei Projektende dadurch entstehende Möglichkeiten demonstrieren.

Arbeitsschwerpunkt in AP5 Lage in der Entwicklung eines NER-Modells (Named-Entity-Recognition) zur Analyse von Warndienstmeldungen. NER ist eine Methode der Informationsextraktion, die darauf abzielt, benannte Entitäten in unstrukturierten Texten zu identifizieren und vordefinierten Kategorien zuzuordnen.

Im Rahmen der Aufstockungsphase (6 Monate) Hortisem-vertical sollten Möglichkeiten untersucht werden, um das Flächenpotential gebäudegebundener Vertical Farming Außenanlagen (z.B. Regalsysteme, Wand-Taschen-Systeme, Gewächshäuser) an Gebäuden unter der Nutzung von 3D-Stadtmodellen (LOD2 und LOD3) in Verbindung mit LiDAR Daten abzuschätzen.

I.2 Ablauf des Vorhabens

Für das Teilvorhaben 5 war der Projektablauf wie folgt strukturiert:

Für die Erstellung eines Named Entity Recognition (NER) Modelle zur automatischen Erkennung und Klassifizierung von relevanten Begriffen des Gartenbaus (Kulturen, Schaderreger, Pflanzenschutzmittel, BBCH Stadium) erfolgt zunächst eine Bestandsaufnahme und Beschreibung der existierenden Warndienstformate. Darauf aufbauend wird die Grundlage für die semantischen Annotationen erarbeitet. Die Warndienstmeldungen der Bundesländer wurden anschließend aufbereitet. Diese Meldungen werden hinsichtlich lexikalischer Einheiten, Phrasen und syntaktischer Strukturen strukturiert und gruppiert. Im Rahmen der Modellierung von Anwendungsfällen und der semantischen Analyse wurden die folgenden Begriffe berücksichtigt:

Für Orts- oder Landschaftsbezeichnungen wurde ein Abgleich mit dem Verzeichnis Geographischer Namen des Bundesamtes für Kartographie und Geodäsie (BKG) vorgenommen. Ein Abgleich mit den BBCH-Stadien wurde durchgeführt. Für Schaderreger und Kultur wird ein Abgleich mit den im Pflanzenschutz üblichen EPPO-Listen sowie weiteren Taxonomien von Schaderregern und Kulturen vorgenommen. Die Übereinstimmungen werden beschrieben und bewertet, um eine genaue Identifikation und Klassifikation der relevanten Schaderreger und Kulturen zu ermöglichen. Für Pflanzenschutzmaßnahmen wurde ein Abgleich mit dem Verzeichnis zugelassener Pflanzenschutzmittel des BVL wird vorgenommen. Relevante Einheiten wurden festgelegt, um die Anwendung und Wirksamkeit der Pflanzenschutzmittel zu analysieren und zu dokumentieren.

Im Rahmen des Projekts wurde ebenfalls der potenzielle Mehrwert durch die Ergänzung der Toxizitätsdaten aus der PPDB (Lewis et al. 2016) geprüft.

In der Aufstockungsphase Hortisem-vertical wurden räumliche Methoden untersucht, um das Flächenpotential gebäudegebundener Vertical-Farming-Anlagen wie Regalsysteme, Wand-Taschen-Systeme und Gewächshäuser an Gebäuden zu ermitteln. Dafür wurden 3D-Stadtmodelle (LOD2 und LOD3) und LiDAR-Daten verwendet.

I.3 Wesentliche Ergebnisse

Anhand gesammelter Pflanzenschutzhinweise und Warnmeldungen wurden Named Entity Recognition (NER¹) Modelle zur automatischen Erkennung und Klassifizierung von relevanten Begriffen des Gartenbaus (Kulturen, Schaderreger, Pflanzenschutzmittel, BBCH Stadium) erstellt. 114 Dateien mit 105737 Wörtern, davon 12295 verschiedene Wörter, wurden verwendet. Mit dem Annotationswerkzeug Prodigy wurden insgesamt 9019 Entitäten annotiert.

Es wurden drei verschiedene Modelle trainiert, basierend auf spaCy, Flair und CRF. Alle drei Modelle erzielten ähnlich gute Genauigkeiten (gemittelte F-Werte), spaCy erreichte mit $F1=0.8997$ die höchste Genauigkeit über alle vier Klassen. Erste Arbeiten fanden statt (de Kock et al. 2023), um das NER Modell als „Interaktionspartner“ mit aktuellen Large Language Models (wie z.B. GPT 3.5 und GPT 4) einzusetzen, wobei die kombinierte Stärke von LLM (eine breitere Zusammenhang erkennen) und das NER (Erkennen und Einstufen von Fachterminen) zu besserer Interpretation der Meldungen führen sollte.

Die Software für das Inventarisieren von Warndienstmeldungen (WMI, de Kock et al. 2021) wurde in einem ersten Schritt als Vergleichstool eingesetzt, um Ausgaben von unterschiedlichen Interpretationsverfahren (z.B. Fachexperte, LLM, NER, LLM + NER Modell, Fachexperte + LLM + NER Modell) zu vergleichen.

In einer weiteren JKI-Zuständigkeit wurde der Mehrwert von Toxizitätsinformation zu PSM in PS Info aus der PPDB untersucht. Im Rahmen einer Befrag wurde herausgearbeitet, dass Toxizitätsdaten zu PSM bei der Beratung einen Mehrwert liefern kann und eine Integration der Daten aus der PPDB angestrebt werden sollte. Nach Prüfung der rechtlichen Voraussetzungen (Regelungen zur Nachnutzbarkeit der PPDB) konnte die Datenbank aber nicht aktiv in PS Info integriert werden.

In der Aufstockungsphase des Projekts Hortisem-vertical wurden räumliche Methoden entwickelt, um das Flächenpotential gebäudegebundener Vertical-Farming-Anlagen zu ermitteln. Dazu zählen Systeme wie Regalsysteme, Wand-Taschen-Systeme und Gewächshäuser an Gebäuden. Um die geeigneten Fassadenbereiche für diese Anlagen zu identifizieren, wurden verschiedene Datentypen verwendet, darunter 3D-Stadtmodelle in den Detailstufen LOD2 (Level of Detail 2) und LOD3 sowie LiDAR-Daten.

¹ NER ist eine Teilaufgabe der Informationsextraktion, die darauf abzielt, benannte Entitäten, die in unstrukturiertem Text erwähnt werden, zu finden und in vordefinierte Kategorien einzuordnen.

Die Untersuchung ergab, dass allein LiDAR-Daten mit einer hohen Punktdichte, wie sie beispielsweise im Digitalen Zwilling verfügbar sind, die Struktur der Fassade hinreichend detailliert erfassen können. Nur so lassen sich die relevanten Merkmale der Fassade in der Art analysieren, um potentiell geeignete Bereiche für die Installation von Vertical-Farming-Anlagen zu identifizieren. Zur Weiterverwertung der Ergebnisse steht das JKI mit dem BKG (Auftraggeber Digitaler Zwilling Deutschland) in Kontakt.

Teil II Eingehende Darstellung

II 1. Darstellung der im Rahmen des Vorhabens durchgeführten Arbeiten, insbesondere im Vergleich zur ursprünglichen Vorhabenbeschreibung. Die Verwendung der Zuwendung sowie die erzielten Ergebnisse im Einzelnen müssen nachvollziehbar sein.

II 1.1 Named-Entity-Recognition (NER)-Modell zur semantischen Analyse von Warndienstmeldungen

Die Anforderungen an die gartenbauliche Beratung und Praxis hinsichtlich des Pflanzenschutzes sind in den Jahren immer komplexer geworden. Die heterogenen Strukturen des Gartenbaus mit einer Vielzahl verschiedener Kulturen und eine Nutzung aller im Pflanzenschutzrecht verankerten Sonderregelungen für Kleinkulturen und Notfallzulassungen stellen für die Akteure hinsichtlich der Datenbeschaffung und Verarbeitung eine besonders große Herausforderung dar. Für die Umsetzung der an den Pflanzenschutz geknüpften rechtlichen Vorgaben benötigen die Akteure einen einfachen und schnellen Handlungsweg, um an die entscheidenden Informationen zu gelangen.

Dieser Handlungsweg sollte mit sowohl menschen- als auch maschinenlesbaren Daten beschrieben werden. Idealerweise sollten die zugrundeliegenden Datenbanken sowohl regional, bundesweit als auch europaweit zuverlässig und rechtssicher miteinander interagieren, beispielsweise über Linked-Data-Prinzipien. Allerdings fungieren die bisher entwickelten Informationssysteme wie die Online-Datenbank des BVL, PS Info, ISIP, hortigate u.a. derzeit als Einzelsysteme und stellen in der Gesamtbetrachtung Insellösungen dar.

Das Gesamtziel des Verbundvorhabens war die Demonstration praxisorientierter und funktionierender Linked-Data-Prinzipien am Beispiel der Beantwortung gartenbaulicher Praxisfragen zum Thema Pflanzenschutz. Das gut eingeführte und breit genutzte System PS Info, welches in der aktuellen Form die Zulassungsdaten des BVL darstellt, soll gartenbauliche Fragestellungen besser bedienen können und diene als Anwendungsbeispiel für die Nutzung von Linked-Data-Prinzipien. Das System sollte bei Projektende dadurch entstehende Möglichkeiten demonstrieren.

Methodisch kamen zwei Technologien zum Einsatz. Die Linked-Open-Data Technologie und die semantische Annotation der Warndienste über Named-Entity-Recognition (NER). Die identifizierten Einzel-Informationen wurden in einem „Knowledge Graph“ (dt. „Wissensgraph“) in einen Zusammenhang gebracht. Erste Schritte für die Datenverknüpfung wurden in PS Info und ISIP umgesetzt.

Das vom JKI entwickelte NER-Modell steht als Webanwendung und als offen zugänglicher und dokumentierter Webservice zur Verfügung. Damit können neue Warndienstmeldungen (aus z.B. Hortigate und / oder andere Quellen) automatisch durch das am JKI entwickelte Named-Entity-Recognition (NER) Model verarbeitet werden.

In der Aufstockungsphase Hortisem-vertical wurden räumliche Methoden untersucht, um das Flächenpotential gebäudegebundener Vertical Farming Außenanlagen (z.B. Regalsysteme, Wand-Taschen-Systeme, Gewächshäuser) an Gebäuden unter der Nutzung von 3D-Stadtmodellen (LOD2 und LOD3) in Verbindung mit LiDAR Daten abzuschätzen.

Die im Projekt gewährten Zuwendungen wurden zur Finanzierung von Projektmitarbeitenden verwendet.

Die Webanwendung mit Suchfunktionalität, um gespeicherte und geparte Warndienstmeldungen nach bestimmten Kriterien abfragen zu können, wurde erweitert und im Intranet des JKI für Testzwecke bereitgestellt.

II 1.2 Sammlung und Aufbereitung von Trainings- und Testdaten

Für das Training des Modells wurde eine umfangreiche Sammlung von Warndiensthinweise der Pflanzenschutzdienste aus verschiedenen Sparten und Bundesländern gesammelt und für die weitere Verwendung im Modellprozess (Trainings- und Testdaten) aufbereitet (Tabellen II 1, Tabellen II2). Warndiensthinweise der Pflanzenschutzdienste sind offizielle Mitteilungen und Empfehlungen, die Landwirte und Gärtner über aktuelle Gefahren und Maßnahmen im Bereich Pflanzenschutz informieren. Diese Hinweise umfassen bspw. Informationen über das Auftreten und die Verbreitung von Schädlingen, Hinweise auf Pflanzenkrankheiten, wetterbedingte Warnungen, die das Pflanzenwachstum und die Schädlingsverbreitung beeinflussen können, Empfehlungen und Warnungen über den Einsatz von Pflanzenschutzmitteln, inklusive neuer Zulassungen oder Rücknahmen oder Anbauempfehlungen zur Fruchtfolge, Anbautechniken und zur Vermeidung von Schädlings- und Krankheitsbefall.

Tabelle II 1: Übersicht der einbezogenen Warndienstmeldungen der Bundesländer als Test- und Trainingsdaten erweitert durch Daten von ISIP e.V. (gelb-Trainingsdaten; rot - interne Kommentierung).

Warndienst in JKI					Warndienst von ISIP	
Bundesland	Bereich	Jahr für Trainingsdaten	verfügbare Jahre	Kommentare	Bereich	Jahre
Brandenburg	Ackerbau	2020	ab 2007		Feldbau	ab 2018
	Baumschule		ab 2010		Baumschule	2020
	Gemüsebau	2020	ab 2008		Gemüsebau	2020
	Obstbau	2020	ab 2008		Obstbau	2020
	Zierpflanzenbau		ab 2010		Zierpflanzenbau	2020
Baden-Württemberg	Gemüsebau	2017	2012-2017	nicht vollständig		
	Obstbau		2012,2013,2016-2018	nicht vollständig		
Hessen	Ackerbau	2017	2011-2018			
	Haus und Kleingarten		2011-2013			
Hopfenring			2015-heute			
Mecklenburg-Vorpommern	Ackerbau Greifswald	2015	2007-2015			
	Ackerbau Neubrandenburg	2020	ab 2012			
	Ackerbau Rostock	2015	2009-2015			
	Ackerbau Schwerin		ab 2010			
	Ackerbau Landesweite Hinweise		ab 2010			
	Obstbau		2010			
Niedersachsen	Ackerbau Sortenempfehlungen		ab 2009			
	Ackerbau Hannover	2014	2013,2014		Ackerbau and Grünland	
	Ackerbau Nienburg		2010-2014		Gartenbau(Gemüse, Obst)	
	Ackerbau Northeim		2007-2014			
Nordrhein-Westfalen	Ackerbau	2019	2008-2011, ab 2013		Ackerbau	ab 2017
Rheinland-Pfalz	Ackerbau		ab 2007		Ackerbau and Grünland	
	Gemüsebau	2020	ab 2012	nicht vollständig		
	Obstbau	2020	ab 2014	nicht vollständig		
Schleswig-Holstein	Ackerbau Ost		ab 2016			
	Ackerbau West		ab 2016			
Sachsen	Ackerbau		ab 2007		Feldbau	
	Gemüsebau	2020	ab 2008		Gemüsebau	ab 2005
	Obstbau		ab 2008		Obstbau	ab 2017
Sachsen-Anhalt	Ackerbau		ab 2008		Baumschulen	ab 2018
					Feldbau	ab 2016
					Gemüsebau	ab 2018
					Obstbau	ab 2015
					Weinbau	ab 2017
					Zierpflanzenbau	ab 2017
Thüringen	Ackerbau		2011-2013, ab 2016		Ackerbau	ab 2017
	Gemüsebau	2020	ab 2018		Obstbau	ab 2017
	Obstbau		ab 2018			
	Wetter		ab 2016			
	Zierpflanzenbau		ab 2018			

Tabelle II 2 gibt eine Übersicht der Trainingsdaten, gegliedert nach den zuvor definierten Ziel-Kategorien: Kultur, Pflanzenschutzmittel (PSM), Erreger, BBCH-Stadien, Witterung, Zeit, Auftreten und Ort. Diese Kategorien strukturieren die Trainingsdaten und ermöglichen eine gezielte Analyse und Anwendung der Informationen im Modell.

Tabelle II 2: Übersicht der Trainingsdaten nach Ziel-Kategorien.

NER Tags	Train	Test
Kultur	6456	1615
Mittel	10514	2629
Erreger	8884	2222
BBCH_Stadium	3540	885
Witterung	1636	410
Zeit	1568	392
Auftreten	1432	358
Ort	1100	275

II 1.3 Erstellung der Datenbank für Trainings- und Testdaten

Tabelle III 3 bietet einen Überblick über die Anzahl der verarbeiteten Trainings- und Testdaten aus Warndienstmeldungen, aufgeschlüsselt nach Bundesländern. Diese Tabelle zeigt, wie viele Datensätze jeweils für das Training und das Testen des Modells verwendet wurden und ermöglicht somit eine Einschätzung der Datenverteilung und Repräsentativität. Die Daten wurden mit dem ML-Modell verarbeitet, als Ergebnis, die extrahierten Entitäten ausgegeben und zusammen mit den Metadaten (Namen der Datei, den Pfad der Datei, den Status der Warnmeldung und das Datum) im JSON-Format in einer Datenbank gespeichert (Abbildung II 1).

Tabelle II 3: Anzahl der verarbeiteten Trainings- und Testdaten aus Warndienstmeldungen nach Bundesland

Warndienst saved in Mongo database					
Bundesland	Stadt	Bereich	verfügbare Jahre in MongoDB	Menge von WD	Kommentare
Brandenburg		Felddbau(scanned)	1994-2006	272	nicht vollständig
		Felddbau	2007-2021	698	
		Baumschule	2010-2021	200	
		Gemueseabau	2008-2021	381	
		Obstbau	2008-2021	428	
		Zierpflanzenbau	2010-2021	215	
Baden-Württemberg		Gemueseabau	2012-2018	156	nicht vollständig
		Obstbau	2012,2013,2016-2018	68	nicht vollständig
Hessen		Felddbau	2011-2018	197	
		Haus und Kleingarten			
Mecklenburg-Vorpommern	Greifswald	Felddbau	2009-2015	256	
	Neubrandenburg	Felddbau	2012-2021	319	
	Rostock	Felddbau	2009-2015	247	
	Schwerin	Felddbau	2010-2021	386	
		Landesweite Hinweise			
		Obstbau			nicht vollständig
		Ackerbau Sortenempfehlungen			
Niedersachsen		Felddbau (Hannover+Nienburg+Northeim)	2007-2014	336	nicht vollständig
Nordrhein-Westfalen		Felddbau	2008, 2010-2011,2013-2021	397	
		Felddbau	2007-2011, 2013-2021	546	
Rheinland-Pfalz		Gemueseabau	2012-2021	384	nicht vollständig
		Obstbau	2014-2020	26	nicht vollständig
Schleswig-Holstein		Felddbau (Obst+West)	2016-2018	111	
Sachsen		Felddbau	2007-2021	693	
		Gemueseabau	2008-2021	387	
		Obstbau	2008-2021	435	
Sachsen-Anhalt		Felddbau	2008-2021	471	
Thüringen		Felddbau	2016-2021	265	
		Gemueseabau	2018-2021	113	
		Obstbau	2018-2021	93	
Total WD in Mongo database:				8080	

Abbildung II 1 zeigt die Struktur dieser JSON-Datei, die als Ausgabe des Modells dient. Diese JSON-Datei ist in hierarchischer Form organisiert und enthält verschiedene Schlüsselfelder und deren zugehörige Werte, die die Ergebnisse des Modells detailliert beschreiben. Die Struktur ermöglicht eine klare und präzise Darstellung der Daten, sodass jede Information leicht zugänglich und verständlich ist. Die JSON-Datei umfasst dabei sowohl numerische Ergebnisse als auch textbasierte Beschreibungen, die in logisch

angeordneten Kategorien zusammengefasst sind, um eine effiziente Analyse und Weiterverarbeitung der Modellausgabe zu ermöglichen.

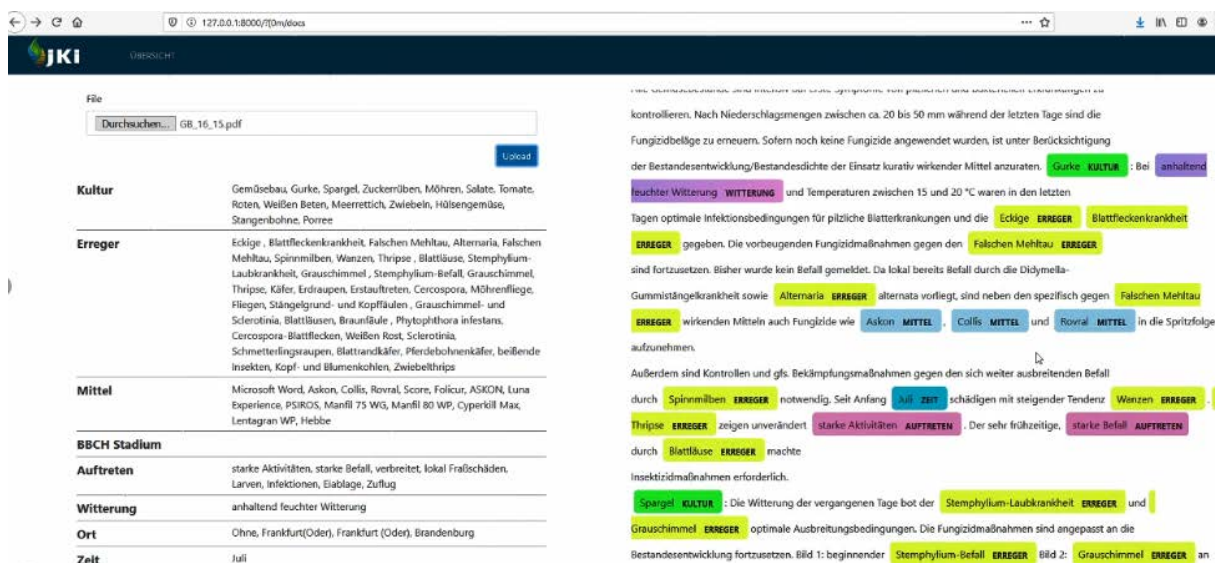
```

fileName: "BB_Zierpflanzenbau_2021 (1).pdf"
filePath: "C:/Users/xia.he/Project/10_Hortisem_neu/data/raw/WD-Meldungen2021/BB/J..."
state: "Brandenburg"
year: "2021"
date: "13.01.2021"
category: "Zierpflanzenbau"
hasImage: "true"
entities: Object
  Kultur: Array
    0: "Lilium-Arten"
    1: "Baumschulgehölzpflanzen"
    2: "Ziergehölzen"
  Erreger: Array
    0: "zweikeimblättrige Unkräuter"
    1: "Unkräuter"
    2: "einjährige, zweikeimblättrige Unkräuter"
    3: "Acker-Fuchsschwanz"
    4: "einjähriges Rispengras"
  Mittel: Array
  BBCH_Stadium: Array
    0: "Austrieb"
    1: "Auflaufen"
  Auftreten: Array
  Ort: Array
  Zeit: Array
    
```

Abbildung II 1: Die Struktur der JSON-Datei der Modellausgabe

II 1.4 Web-Anwendung zur Visualisierung der Modellergebnisse

Eine Webanwendung wurde entwickelt, um die Daten zu visualisieren, wobei Schlüsselfelder und deren zugehörige Werte hervorgehoben werden. Der Benutzer hat die Möglichkeit, eine PDF-Datei hochzuladen, die anschließend eingelesen und analysiert wird. Die verschiedenen erkannten Entitäten werden in unterschiedlichen Farben dargestellt, um eine klare und intuitive Übersicht der enthaltenen Informationen zu ermöglichen.



The screenshot shows a web application interface with a file upload section on the left and a detailed analysis report on the right. The report text is annotated with colored boxes corresponding to the JSON entities: Kultur (purple), Erreger (green), Mittel (yellow), BBCH Stadium (orange), Auftreten (red), Witterung (blue), Ort (grey), and Zeit (grey).

Entity	Value
Kultur	Gemüsebau, Gurke, Spargel, Zuckerrüben, Möhren, Solate, Tomate, Rote, Weißen Bete, Meerrettich, Zwiebeln, Hölsengemüse, Stangenbohne, Porree
Erreger	Eckige Blattockenkrankheit, Falschen Mehltau, Alternaria, Falschen Mehltau, Spinnmilben, Wanzen, Thripse, Blattläuse, Stenophyllum-Laubkrankheit, Grauschimmel, Stemphylium-Befall, Grauschimmel, Thripse, Käfer, Erdkräppler, Erstaufreten, Cercospora, MDKrennfliege, Fliegen, Stängelgrund- und Kopffäulen, Grauschimmel- und Sclerotinia, Blattläuse, Braunfäule, Phytophthora infestans, Cercospora, Blattflecken, Weißen Rost, Sclerotinia, Schmetterlingsraupen, Blattkäfer, Pfirsichbohnenkäfer, beißende Insekten, Kopf- und Blütenkohlen, Zwiebelthrips
Mittel	Microsoft Word, Askon, Collis, Rovral, Score, Folicur, ASKON, Luna Experience, PSIROG, Manfl 75 WG, Manfl 80 WP, Cyperkill Max, Lentgran WP, Hebbe
BBCH Stadium	
Auftreten	starke Aktivitäten, starke Befall, verbreitet, lokal Fraßschäden, Larven, Infektionen, Eiablage, Zullug
Witterung	anhaltend leichter Witterung
Ort	Ohne, Frankfurt(Oder), Frankfurt (Oder), Brandenburg
Zeit	juli

Abbildung II 2: Protokoll Web-Anwendung zur Visualisierung der Modellergebnisse

II 1.5 Bildextraktion aus den Warndienstmeldungen

Das JKI hat aus den Warndienstmeldungen Schaderregerabbildungen mit Annotationen extrahiert und indiziert. Diese Daten (Abbildung II3) sowie detaillierte Informationen (Tabelle 6) wurden dem Projekt zur Verfügung gestellt, um die Abbildungen in den Wissensgraphen einzufügen. Der Wissensgraph verknüpft die Abbildungen mit Kulturpflanzen und/oder Schadorganismen



Abbildung II 3: Beispiele für aus den Warndienstmeldungen extrahierte Schaderregerabbildungen

II 1.6 Named Entity Recognition (NER) Model

Anhand gesammelter Pflanzenschutzhinweise und Warnmeldungen wurden Named Entity Recognition (NER) Modelle entwickelt, um automatisch relevante Begriffe im Gartenbau wie Kulturen, Schaderreger, Pflanzenschutzmittel und BBCH-Stadium zu erkennen und zu klassifizieren. Für das Training wurden 114 Dateien mit insgesamt 105.737 Wörtern genutzt, darunter 12.295 verschiedene Wörter. Mit dem Annotationswerkzeug Prodigy wurden insgesamt 9.019 Entitäten annotiert. Es wurden drei Modelle auf Basis von spaCy, Flair und CRF trainiert. Alle drei Modelle erreichten ähnlich hohe Genauigkeiten (gemessene F1-Werte), wobei spaCy mit einem F1-Wert von 0.8997 die beste Gesamtgenauigkeit über alle vier Klassen erzielte.

Die Übergabe des NER-Modells - Das trainierte des NER-Modells wurde dem Konsortium zur weiteren Bearbeitung bereitgestellt. Das Modell wurde mit folgender Modellgüte übergeben (vgl. Tabelle II 4 und Tabelle II 4).

Tabelle II 4: Übersicht der Modellgüte nach Ziel-Kategorien.

Tag	Precision	Recall	F1
Kultur	0.9021	0.8883	0.8952
Erreger	0.8711	0.8654	0.8683
Mittel	0.8657	0.8709	0.8683
BBCH_Stadium	0.7833	0.7556	0.7692
Zeit	0.6067	0.4615	0.5242
Auftreten	0.4314	0.2115	0.2838
Ort	0.8526	0.7168	0.7788
Witterung	0.5238	0.2857	0.3697

Tabelle II 5 bietet eine Übersicht der Modellgüte der verschiedenen Modelle, die in der Analyse verwendet wurden: SpaCy, Flair und CRF (Conditional Random Fields). Die Tabelle zeigt Leistungsmetriken wie Präzision, Recall und F1-Score für jedes Modell, um deren Effektivität bei der

Erkennung und Klassifizierung von Entitäten zu bewerten. Diese Vergleichsdaten ermöglichen es, die Stärken und Schwächen der einzelnen Modelle zu identifizieren und die geeignetste Methode für die jeweilige Anwendung auszuwählen.

Tabelle II 5: Übersicht der Modellgüte nach Modellen.

Model	Precision	Recall	F1
Spacy	0.8947	0.9048	0.8997
Flair	0.8524	0.8978	0.8745
CRF	0.905	0.87	0.887

II 1.7 Web-Anwendung Warndienstmeldungsinventar (WMI)

Es wurde eine interne Web-Anwendung (WMI-Warndienstmeldungsinventar) entwickelt, um Warndienstmeldungen nach speziellen Kriterien auf Grundlage des NER-Modells zu recherchieren. In die Anwendung wurde eine Baumansicht mit Kultur als Wurzel integriert. Die Maßnahmen können bis zur Kennnummer des Pflanzenschutzmittels gespeichert werden.

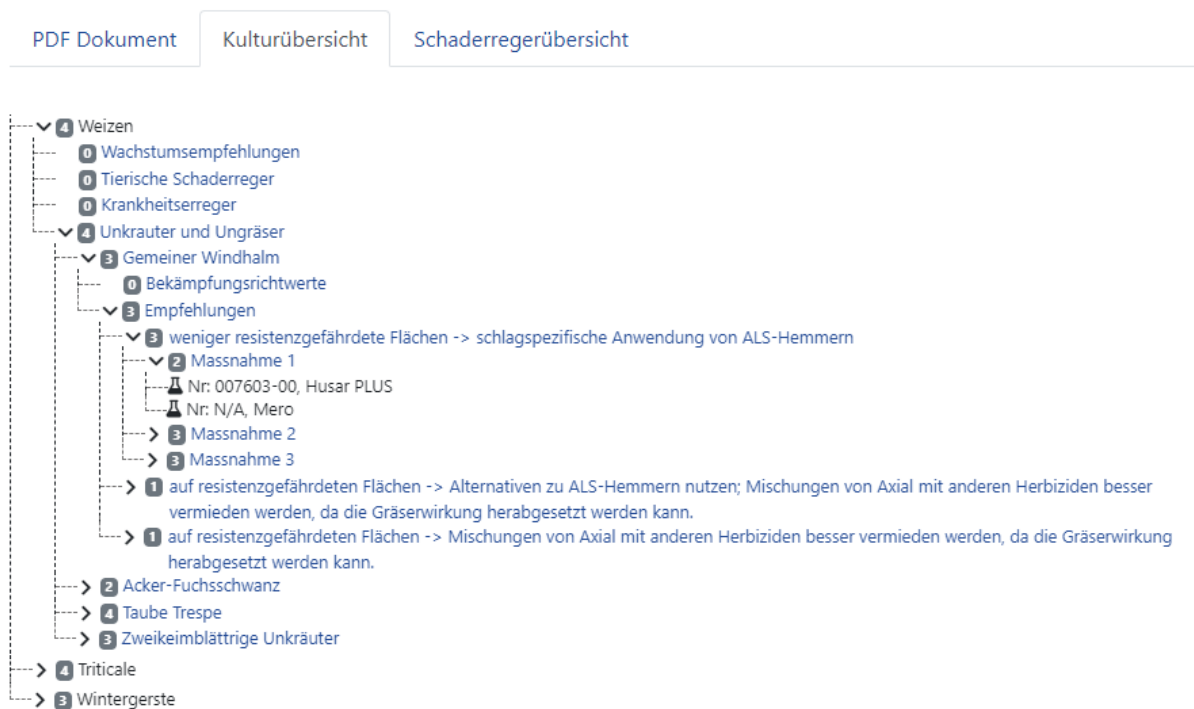


Abbildung II4 GUI der Web-Anwendung WMI-Warndienstmeldungsinventar

Darstellung der Oberfläche der WMI-Oberfläche wurde erweitert, sodass neben einem Zugang über Kultur auch ein Zugang über Schaderreger verfügbar ist. Beide Bäume werden nach jeder Eingabe automatisch aktualisiert (Abbildung II5).

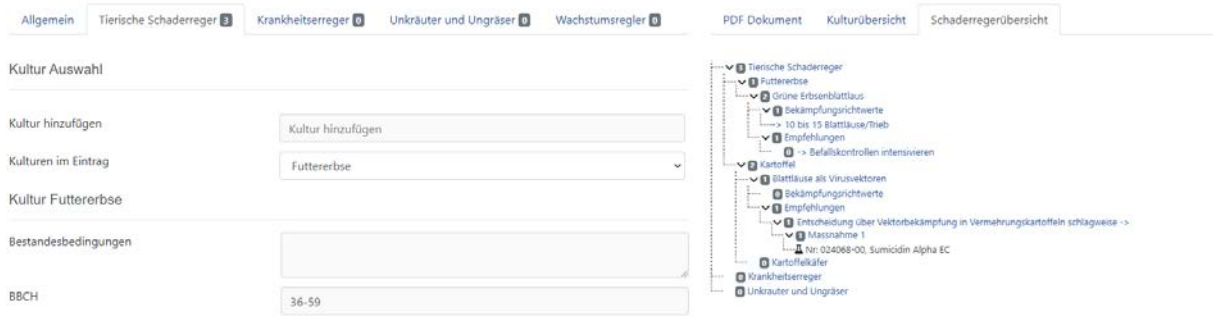


Abbildung II5 GUI der Web-Anwendung WMI-Warndienstmeldungsinventar: Zugang über Kulturen und Schaderreger

Es kann im rechten Teil der WMI-Oberflächen zwischen der Schaderregerübersicht und der Darstellung des analysierten Dokuments gewechselt werden. Auf der linken Seite können die gesammelten Informationen des Dokuments, welche entweder manuell durch DomainexpertInnen oder automatisch durch die KI erfasst wurden, strukturiert eingegeben und gespeichert werden (Abbildung II6).

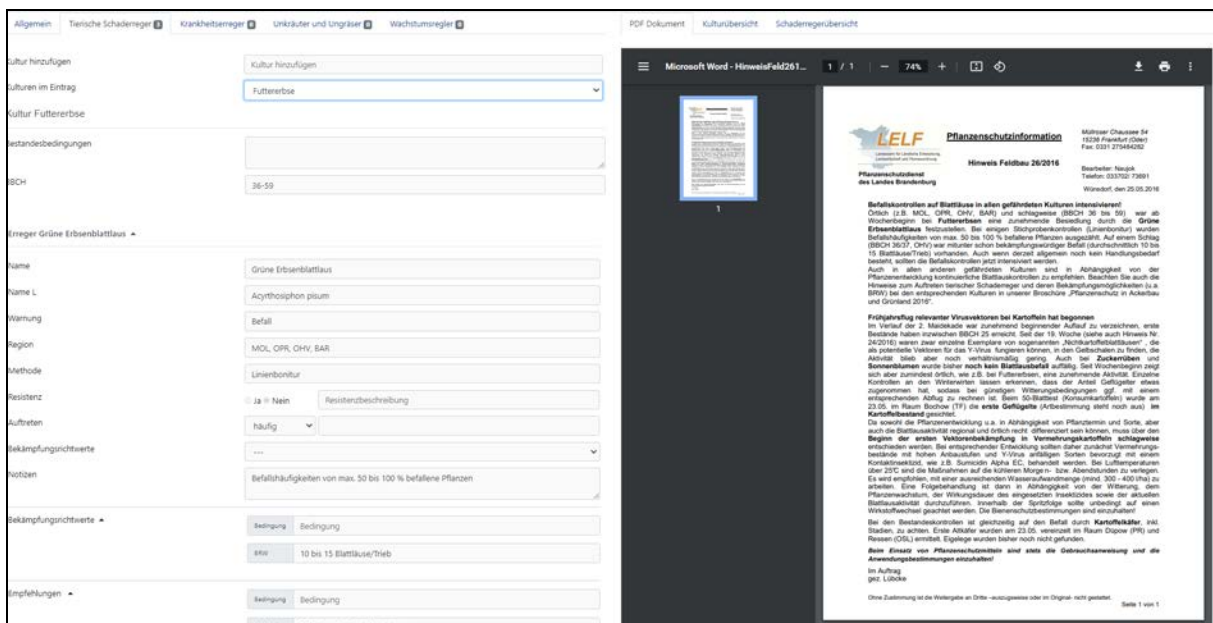


Abbildung II6 GUI der Web-Anwendung WMI-Warndienstmeldungsinventar: Schaderregerübersicht und Dokumentenansicht

Unter anderem wurde ein „AI Sidekick“ integriert, der DomainexpertInnen die Möglichkeit bietet, die KI-Ausgabe pro Kultur, Schaderreger und Maßnahme einzuschätzen. Beim Akzeptieren der Ausgabe wird die KI-Eingabe in das Eingabeformular übernommen; bei Ablehnung gibt es die Möglichkeit, den Grund zu kommentieren (Abbildung II7).

AI Sidekick

Allgemein

Datum: 12.08.2016

Einrichtung: Pflanzenschutzdienst des Landes Brandenburg

Beratungsregion: Wünsdorf

Bundesland: Brandenburg

Bearbeiter: Tümmler/ Naujok

Nummer: Hinweis Feldbau 43/2016

Kulturen

Winterraps => winterraps / BBCH Nicht spezifiziert

Erreger gefunden für Winterraps

Unkräuter => Unkräuter

Gefleckter Schierling => gefleckter Schierling

Hundskerbel => Hundskerbel

Ackerkrummhals => Ackerkrummhals

Behandlungen für Winterraps, gegen Unkräuter

Winterraps / Unkräuter as id 2785 / pathogen id 509 as unkraut

Anwendung von integriertem Unkrautbekämpfungskonzept mit breitwirksamen Behandlungen im Voraufbau oder frühen Nachaufbau. Anwendung von Herbiziden wie Stomp Aqua, Quantum, Butisan Top, Fuego Top, Butisan Gold, Colzor Trio und clomazone-haltigen Produkten. Restverunkrautung mit selektiv wirksamen Nachaufbauherbiziden wie Runway, Effigo, Milestone, und Fox behandelt. | PSM: Stomp Aqua, Quantum, Butisan Top, Fuego Top, Butisan Gold, Colzor Trio, clomazone-haltige Produkte, Runway, Effigo, Milestone, Fox | Appl.: Voraufbau oder früher Nachaufbau, selektiv wirksamer Nachaufbau

Abbildung I17 AI Sidekick: KI-Ausgabe pro Kultur, Schaderreger und Maßnahme als Vorschlag des KI-Modells

Web-Service: Für das einlesen und analysieren der Warndienstmeldungen wurde ein Web-Service entwickelt und dokumentiert. Der Service ist offen zugänglich: <https://sf.julius-kuehn.de/hortisem/docs#/>

Die Dokumentation ist im gängigen „Open API“-Format verfügbar. Mittels der JavaScript- und HTML-Bibliothek „Swagger“ kann die API auch direkt ausprobiert werden. Zwei Endpunkte stehen zur Verfügung: einer für das Analysieren eines PDF-Dokuments und ein zweiter für das Analysieren von freiem Text (Abbildung I18).

HortiSem.Named_Entity_Recognition 0.0 OAS3

hortisemopenapi.com

Impressum: <https://sf.julius-kuehn.de/#impressum>

Servers: /hortisem

default

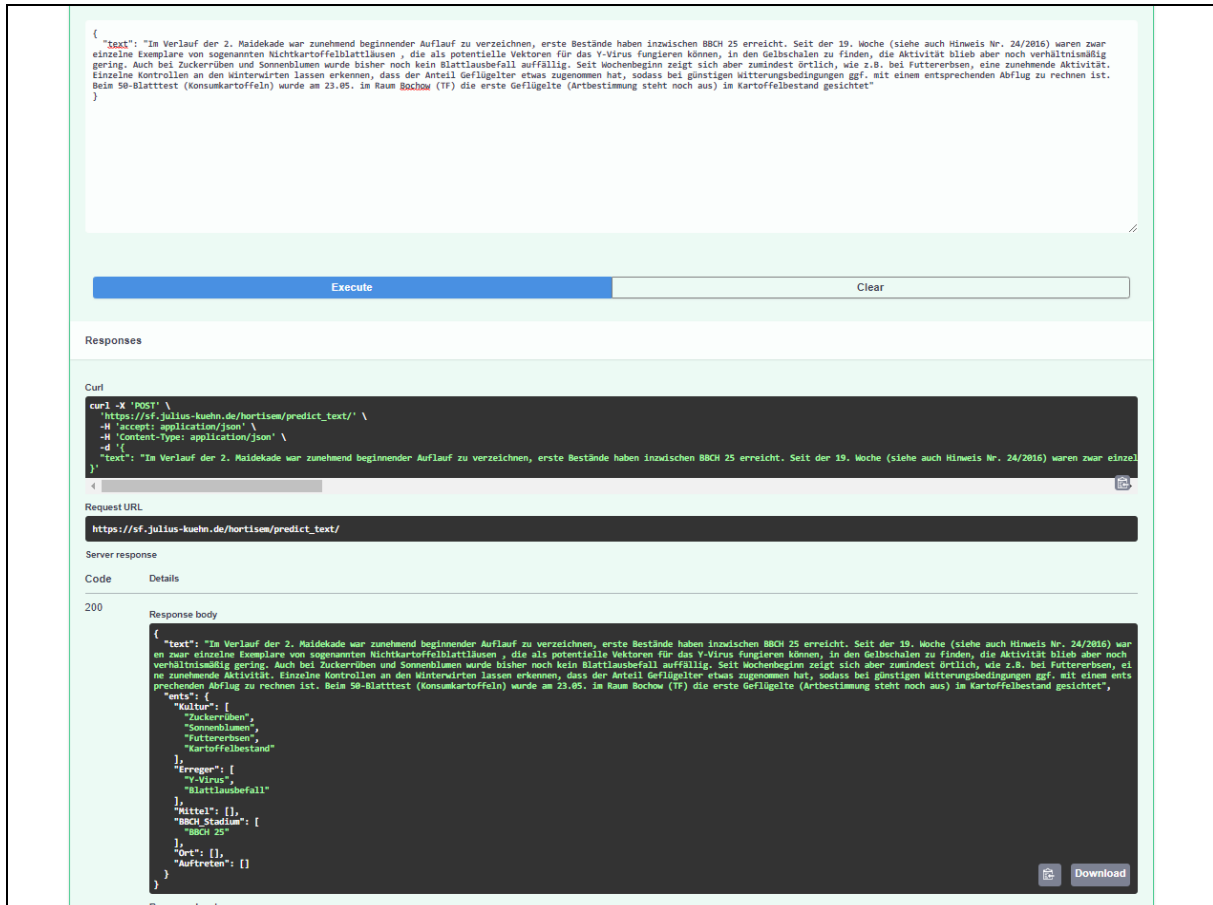
- POST /predict_pdf/ Create Upload File
- POST /predict_text/ Predict Text

Schemas

- Body_create_upload_file_predict_pdf_post
- Data
- HTTPValidationError
- ValidationError

Abbildung I18 Dokumentationsstruktur im gängigen „Open API“-Format

Die API-Dokumentationsseite bietet die Möglichkeit, die zu übermittelnden Parameter direkt zu bearbeiten, wonach die API per Knopfdruck abgefragt werden kann. Antworten der API kommen im üblichen JSON-Format zurück, wodurch andere Systeme die Informationen mit breit verfügbaren Bibliotheken einlesen und verarbeiten können (Abbildung II9).



The screenshot displays a Swagger REST client interface. At the top, a text input field contains a JSON object with a 'text' property. Below the input are 'Execute' and 'Clear' buttons. The 'Responses' section shows the 'Curl' command used for the request, the 'Request URL' (https://sf.julius-kuehn.de/hortisem/predict_text/), and the 'Server response' (200). The 'Response body' is a JSON object with the following structure:

```
{
  "text": "Im Verlauf der 2. Maidekade war zunehmend beginnender Aufflug zu verzeichnen, erste Bestände haben inzwischen BBCH 25 erreicht. Seit der 19. Woche (siehe auch Hinweis Nr. 24/2016) waren zwar einzelne Exemplare von sogenannten Nichtkartoffelblattläusen, die als potentielle Vektoren für das V-Virus fungieren können, in den Gelbschalen zu finden, die Aktivität blieb aber noch verhältnismäßig gering. Auch bei Zuckerrüben und Sonnenblumen wurde bisher noch kein Blattlausbefall auffällig. Seit Wochenbeginn zeigt sich aber zumindest örtlich, wie z.B. bei Futtererbsen, eine zunehmende Aktivität. Einzelne Kontrollen an den Winterwärdern lassen erkennen, dass der Anteil Geflügelter etwas zugenommen hat, sodass bei günstigen Witterungsbedingungen ggf. mit einem entsprechenden Abflug zu rechnen ist. Beim 50-Blatttest (Konsumkartoffeln) wurde am 23.05. im Raum Bochow (TF) die erste Geflügelte (Artbestimmung steht noch aus) im Kartoffelbestand gesichtet",
  "ents": {
    "kult": [
      "Zuckerrüben",
      "Sonnenblumen",
      "Futtererbsen",
      "Kartoffelbestand"
    ],
    "erreg": [
      "V-Virus",
      "Blattlausbefall"
    ],
    "mittel": [],
    "bbch_stadium": [
      "BBCH_25"
    ],
    "ort": [],
    "auftreten": []
  ]
}
```

Abbildung II9 Testumgebung der JavaScript- und HTML-Bibliothek „Swagger“

II 1.8 Aufstockungsphase Hortisem-vertical

Im Rahmen der 6-monatigen Aufstockungsphase Hortisem-vertical wurden Möglichkeiten untersucht, um das Flächenpotential gebäudegebundener Vertical Farming Außenanlagen (z.B. Regalsysteme, Wand-Taschen-Systeme, Gewächshäuser) an Gebäuden unter der Nutzung von 3D-Stadtmodellen (LOD2 und LOD3) in Verbindung mit LiDAR Daten abzuschätzen.

II 1.8.1 Hintergrund

Vertical Farming umfasst innovative Technologien, die einen Beitrag zur nachhaltigen und sicheren Versorgung der Menschen mit pflanzlichen Lebensmitteln leisten können. Gerade im urbanen Bereich gewinnt Vertikale Landwirtschaft bzw. Vertical Farming als eine Form der urbanen Landwirtschaft (Feldmann et al. 2023) zunehmend an Bedeutung.


Vertikale Landwirtschaft kann definiert werden als Anbau in die Höhe statt in die Breite mit dem Ziel, mehr Lebensmittel auf weniger Fläche zu produzieren (Al-Kodmany, 2018). Die flächenunabhängige Landwirtschaft ist eine Form der urbanen Landwirtschaft, die die traditionelle bodengebundene Landwirtschaft ergänzt, indem sie Synergien zwischen Gebäuden und Landwirtschaft schafft. Sie ist zwar durch einzigartige technische Herausforderungen eingeschränkt, bietet aber auch Möglichkeiten zur Ressourceneffizienz (Thomaier et al., 2015).

Gebäudegebundene VF-Außenanlagen sind Varianten des Vertical Farming, bei dem Pflanzen an der Außenwand von Gebäuden angebaut werden. Diese Methode hat das Potenzial, ungenutzte städtische Flächen zu nutzen, indem sie vertikale Flächen für die Nahrungsmittelproduktion nutzt. Die Vorteile von VF-Außenanlagen sind vielfältig. Sie können – wie auch indoor-Varianten - dazu beitragen, den lokalen Nahrungsmittelbedarf zu decken und die Transportkosten und die damit verbundene Umweltbelastung zu reduzieren.

Die VF-Außenanlagen können auch dazu beitragen, das Mikroklima in Städten positiv zu beeinflussen. Lebende oder grüne Wände sind fortschrittliche Systeme mit integrierter Bewässerung, Abdichtung, Überwachung und Beleuchtung, die ein komplexeres Ökosystem schaffen, das den Luftstrom verbessert und die Luftfeuchtigkeit erhöht, was zu einem geringeren Energieverbrauch und niedrigeren Betriebskosten führt (Lee & Chuang, 2017). Wenn diese Systeme auf breiter Basis umgesetzt werden, verbessern sie die urbane Biodiversität, die Regenwasserbewirtschaftung, die Luftqualität, die Temperaturen und den Wärmeinseleffekt (Manso & Castro-Gomes, 2015). Ein Beispiel aus Stuttgart zeigt, dass Gebäude mit Grünflächen die Fassadentemperaturen um bis zu 50 % senken (Lee & Chuang, 2017). Sie bieten ein breites Spektrum an Vorteilen, darunter ästhetische, gesellschaftliche, wirtschaftliche, gesundheitliche und ökologische Vorteile (Manso & Castro-Gomes, 2015, Lee & Chuang, 2017). Die Idee der grünen Wände umfasst alle Systeme, die eine Begrünung von vertikalen Flächen ermöglichen, und schließt alle Lösungen ein, die für den Anbau von Pflanzen an, auf oder in den Wänden eines Gebäudes konzipiert sind (Manso & Castro-Gomes, 2015).

LiDAR-Scanner können anhand der Plattformen, auf denen sie montiert sind, klassifiziert werden. Luftgestützte Laserscanner (Airborne Laser Scanners, ALS) werden eingesetzt, wenn LiDAR-Messungen aus der Vogelperspektive in Höhen von einigen Metern bis zu mehreren Kilometern auf Drohnen, Helikoptern oder Flugzeugen durchgeführt werden. Weltraumgestützte Laserscanner (SLS) arbeiten von Satelliten aus und erfassen Daten aus noch größeren Höhen. Es gibt terrestrische Laserscanner (TLS), die Messungen vom Boden aus durchführen und stationär oder mobil sein können, mit mobilen terrestrischen Laserscannern (MTLS), die auf terrestrischen Fahrzeugen montiert sind, und tragbaren terrestrischen Laserscannern (PTLS), die von Menschen getragen werden (Pérez et al., 2021). Obwohl sich in den letzten Jahren die Dichte der mit ALS-Scannern erfassten Punkte verbessert hat, ist die vertikale Datenerfassung für die Klassifizierung vertikaler Merkmale immer noch zu spärlich. Dies kann

durch die Kombination mehrerer, sich überschneidender Flugbahnen in geringerer Höhe und mit geringerer Geschwindigkeit verbessert werden (Abbildung II 1.8.1) (Stanley & Laefer, 2021).



a) Brooklyn Army Terminal from 2017 scan (NYC DOITT 2018)



b) Brooklyn Army Terminal from 2019 scan (Laefer and Vo 2020)

Abbildung II 1.8.1 Unterschied in der Punktdichte in zwei Punktwolken, wobei die zweite eine Dichte von 570 pts/m² aufweist (Stanley & Laefer, 2021)

II 1.8.2 Untersuchte Prozess-Pipeline

Zunächst wurde die Datenverfügbarkeit durch Gespräche über die Nutzung und Verfügbarkeit der benötigten Daten geprüft. Es wurden mehrere Interessensgebiete bzw. verschiedene Städte in Betracht gezogen, darunter Daten aus München, Köln, Hamburg und Berlin. Letztendlich entschied man sich für einen Teil Berlins als Testgebiet aufgrund der Nähe zum Forschungsstandort (für die Erhebung von Groud-truth Daten) und der Open-Data-Politik der Stadt Berlin. Zunächst wurde eine visuelle Inspektion von digitalen Orthofotos (DOP) für Berlin durchgeführt, um geeignete Gebiete als Untersuchungsstandorte zu identifizieren.

DOP liefern hochauflösende Luftbilder, die für die Beurteilung der Stadtlandschaft und die Identifizierung spezifischer, für die Studie relevanter Merkmale unerlässlich sind. Nach der Eingrenzung der Auswahl wurden diese Gebiete besichtigt, was zu der Entscheidung führte, sich auf die Stadtteile Rummelsburg und Friedrichsfelde (Ortsteil) zu konzentrieren und den Weitlingkiez als Zentrum der Analyse festzulegen. Dieses Gebiet wurde als Testgebiet ausgewählt, weil es eine vielfältige Mischung von städtischen Merkmalen bietet, einschließlich einer Vielzahl von Gebäudetypen, Grünflächen und Infrastrukturelementen wie Straßen und Bahnlinien (Abbildung II 1.8.2).



Abbildung II 1.8.2 Eines der Untersuchungsgebiete in Berlin

Dieses Gebiet umfasst eine Mischung aus Wohn- und Geschäftshäusern, Parks und öffentlichen Räumen. Diese Vielfalt bietet eine umfassende Umgebung, um die Wirksamkeit von LiDAR-Daten bei der Erfassung verschiedener städtischer Elemente zu testen.

Das ausgewählte Gebiet ist durch umliegende Verkehrswege wie Bahnlinien und Straßen gut abgegrenzt, die natürliche Grenzen für die Studie darstellen. Dies erleichtert die Abgrenzung des Untersuchungsgebiets und die Durchführung der Datenerfassung. Im gesamten Gebiet gibt es eine große Anzahl von Bäumen in der Nähe von Gebäuden, die die LiDAR-Ergebnisse beeinträchtigen können. Die Prüfung der Hypothese in einem Gebiet mit hohem Baumbestand war entscheidend für das Verständnis und die Abschwächung der möglichen Auswirkungen der Vegetation auf die LiDAR-Datenerfassung und -analyse. Das Vorhandensein von Bäumen ermöglicht die Bewertung der Fähigkeit von LiDAR, das Kronendach zu durchdringen und das darunter liegende Gelände und die Strukturen genau zu erfassen. Die Nähe des Gebiets zum Standort des JKI Kleinmachnow spielte bei der Auswahl eine Rolle, da sie eine einfachere logistische Planung und häufigere Ortsbesuche ermöglichte. Dies war wichtig für die Geländearbeiten zur Validierung der LiDAR-Daten und der abgeleiteten Ergebnisse.

Nach der Festlegung des Untersuchungsgebiets wurden LiDAR-Daten gesammelt. Die berliner LiDAR-Daten bestanden aus 13 Schichten, jede mit einer Fläche von 1 km². Im Durchschnitt hatten die LiDAR-Daten 13,62 Punkte pro Quadratmeter (Tabelle II 1.8.1).

Tabelle II 1.8.1 Verwendete LiDAR-Daten für Berlin

Nr.	Name	Anzahl der Punkte	
1	33_336_5816	10 814 522	
2	33_336_5817	13 609 046	
3	33_337_5816	10 139 373	

4	33_337_5817	13 820 758	
5	33_337_5818	13 510 388	
6	33_338_5816	12 571 115	
7	33_338_5817	16 099 840	
8	33_338_5818	14 250 358	
9	33_338_5819	13 297 568	
10	33_339_5816	13 898 654	
11	33_339_5817	15 728 255	
12	33_339_5818	15 131 309	
13	33_339_5819	14 144 089	
		177 015 275	Summe
		13,62	pt/m²

Außerdem wurden Gebäudemodelle für die Stadt Berlin unterschiedlicher Detaillierungsgrade (Level of Detail, LoD), zusammengetragen. Der LoD bezieht sich auf den Grad der Detailliertheit und Genauigkeit der Daten, in diesem Fall, der Darstellung von Gebäuden und städtischen Merkmalen. Verschiedene LoDs bieten unterschiedliche Granularitätsstufen, von einfachen Blockmodellen bis hin zu detaillierten architektonischen Merkmalen (Abbildung II 1.8.3). Sie sind eine Progression der grafischen Darstellung des Modells von einfachen 2D-Formen bis hin zu komplexen Modellen mit einer unterschiedlichen Menge an hinzugefügten Informationen (Fai & Rafeiro, 2014).




Abbildung II 1.8.3 Unterschiedliche LoD und wie sich die Modelle ändern (URL3)

Zum Beispiel sind LoD1-Daten für ganz Deutschland verfügbar, aber aufgrund ihres geringen Detaillierungsgrads waren sie nicht geeignet. LoD1 enthält in der Regel einfache Gebäudeformen ohne detaillierte Merkmale. Im Gegensatz dazu bieten LoD3-Daten sehr detaillierte Modelle, einschließlich architektonischer Elemente wie Fenster und Türen, aber dieser Detaillierungsgrad ist nicht überall

verfügbar. Daher wurde beschlossen, für die Forschung LoD2-Daten zu verwenden. LoD2 ist eine gute Option in Ermangelung von LoD3, denn es bietet detailliertere Gebäudeformen, einschließlich Dachstrukturen und wichtiger architektonischer Merkmale als LoD1, und ist im Allgemeinen eine geometrisch genauere Darstellung von Objekten aus der realen Welt.

Die LoD2-Daten wurden in zwei Formaten heruntergeladen: CityGML und OBJ. Die Arbeit mit CityGML-Daten erwies sich als problematisch. Obwohl sie detailliertere Informationen wie die Vorklassifizierung von Wänden und Dächern sowie Höheninformationen enthalten, stellten sie aufgrund von Unerfahrenheit und fehlender Software zur effektiven Handhabung dieses Datenformats eine Herausforderung dar. Ursprünglich wurde Esri ArcGIS Pro für die Arbeit mit CityGML verwendet, aber dieser Ansatz war zeitaufwändig und nicht skalierbar. Das CityGML-Datenformat erforderte einen erheblichen manuellen Aufwand für die Verarbeitung und Integration. Dagegen erwies sich das OBJ-Format als handhabbarer. Es ist ein einfacheres Format, das leicht in verschiedene 3D-Modellierungs- und GIS-Software importiert werden kann. Dies ermöglichte eine Rationalisierung des Arbeitsablaufs und die Konzentration auf die Analyse der Daten, anstatt sich mit technischen Schwierigkeiten auseinanderzusetzen. Zusammenfassend lässt sich sagen, dass CityGML zwar mehr Informationen bietet, aber ohne die richtigen Werkzeuge und Fachkenntnisse eine Herausforderung darstellen kann. Obwohl das OBJ-Format weniger Informationen bietet, wurde es als optimale Lösung für diese Untersuchung gewählt (Abbildung II 1.8.4).




Abbildung II 1.8.4 3D-Modell der Gebäude für die weitere Analyse

Während der Entwicklung der Methodik wurden vom Bundesamt für Kartographie und Geodäsie (BKG) digitale Zwillingsdaten für die Stadt Hamburg zur Verfügung gestellt. Dadurch ergab sich die Möglichkeit, die entwickelte Methodik mit LiDAR-Daten unterschiedlicher Qualität zu vergleichen. Die Daten für Hamburg sind etwa fünfmal so detailliert wie die für Berlin (Abbildung II 1.8.5). Dieser höhere Detaillierungsgrad bringt auch andere Herausforderungen mit sich, wie z.B. die Bearbeitung und Handhabung größerer Datensätze. Der Hamburger Datensatz, der detaillierter ist, wirft einzigartige Probleme auf. So erforderte die Verwaltung und Verarbeitung größerer Datenmengen mehr Rechenleistung und fortschrittliche Datenverwaltungstechniken. Außerdem waren auch die Hamburger Daten klassifiziert, was die Möglichkeit bot, die Genauigkeit und Zuverlässigkeit dieser Klassifizierung zu bewerten. Bei der Bewertung der Qualität der klassifizierten Daten musste überprüft werden, wie gut die Klassifizierung angesichts der hohen Punktdichte mit den tatsächlichen Merkmalen übereinstimmte.



Abbildung II 1.8.5 Digitale Zwillingdaten des BKG für das Untersuchungsgebiet in der Stadt

Ein wesentlicher Vorteil der Digital Zwillingdaten aus Hamburg ist, dass sie RGB-Informationen für jeden LiDAR-Punkt enthalten. Diese zusätzlichen Farbdaten erleichtern die Validierung der Ergebnisse, da sie einen visuellen Querverweis der Punkte mit ihren realen Gegenständen ermöglichen. Mit anderen Worten: Die RGB-Informationen verringern die Notwendigkeit einer Überprüfung vor Ort, da sie eine genauere und effizientere Identifizierung und Klassifizierung von Merkmalen direkt im Datensatz ermöglichen. Durch die Integration dieser qualitativ hochwertigeren Daten aus Hamburg konnte die Forschung von einer vergleichenden Analyse profitieren, die die Stärken und Grenzen der verschiedenen Datenaufösungen und Klassifizierungsmethoden aufzeigt. Dieser Vergleich verbessert nicht nur die Robustheit der Methodik, sondern gibt auch Aufschluss darüber, wie sich unterschiedliche Datenqualitäten auf die Gesamtgenauigkeit und Effizienz der Stadtmodellierung und -analyse auswirken. Das zur Verfügung stehende Gebiet war nur 1 km² groß und umfasste 64.021.421 Punkte mit einer Punktdichte von 64 Pt/m².

Bei den Berliner Daten bestand der erste Schritt bei der Arbeit mit LiDAR darin, alle Bodenpunkte zu eliminieren. Da die Daten bereits klassifiziert waren, konnte diese Aufgabe mit Hilfe spezieller Python-Module leicht bewältigt werden. Es wurde ein Code zum Herausfiltern von Bodenpunkten entwickelt (Abbildung II 1.8.6). Dieser Code wird für die zukünftige Verwendung und als Referenz zur Verfügung gestellt.




Abbildung II 1.8.6 LiDAR-Daten nach dem Entfernen von Bodenpunkten

Um eine effektive statistische Analyse zu gewährleisten, war es notwendig, den Datensatz zu reduzieren, indem Bodenpunkte entfernt wurden, die eine erhebliche Anzahl von Datenpunkten

darstellen und die Analyse erschweren könnten. Durch diesen Reduktionsprozess wurde die Gesamtzahl der Punkte für die Berliner Daten auf 85.444.864 reduziert, was zu einer durchschnittlichen Dichte von 6,57 Punkten pro Quadratmeter führt. Ein ähnlicher Reduktionsprozess wurde auf die Daten für Hamburg angewandt, wodurch sich die Anzahl der Punkte auf 23.842.192 verringerte, was einer durchschnittlichen Dichte von 23,8 Punkten pro Quadratmeter entspricht.

Die Arbeit am Stadtmodell folgte einem ähnlichen Prozess. Da dieses Modell nur Gebäude enthielt, war es nicht notwendig, Polygone zu entfernen, die den Boden darstellen. Da jedoch nur Polygone, die Wände darstellen, von Interesse waren, musste das Modell weiter verfeinert werden. Diese Verfeinerung wurde mit Python durchgeführt (Abbildung II 1.8.7).




Abbildung II 1.8.7 3D-Modell ohne Dachpolygone

Das Modell mit den Gebäuden wurde zunächst in Polygone zerlegt, die Wände und Dächer darstellen. Anschließend wurde jede Seite des Gebäudes einzeln separiert. Diese Trennung lieferte zusätzliche Informationen, die zuvor nicht verfügbar waren, wie z. B. die Ausrichtung der Wände, die für Vertical-Farming-Anwendungen besonders wichtig ist.

Im Ergebnis die Berliner LiDAR-Daten nur noch aus Punkten, die keine Bodenpunkte waren, und die 3D-Modelle bestanden nur noch aus Polygonen, die Wände darstellen. Dieser Verfeinerungsprozess stellte sicher, dass die Daten speziell auf die Bedürfnisse der Analyse zugeschnitten waren, was genauere und relevantere Ergebnisse ermöglichte. Das Python-Skript, das für diesen Prozess verwendet wurde, wird zur Verfügung gestellt und stellt eine wertvolle Ressource für andere dar, die mit ähnlichen Daten oder OBJ-Gebäudemodellen arbeiten. Durch die Automatisierung der Klassifizierungs- und Trennungsaufgaben steigert das Skript die Effizienz und Genauigkeit der Datenverarbeitung und erleichtert es, sich auf die anschließende Analyse und Anwendung der Daten zu konzentrieren.

Das Modell und die Punktwolke haben sich nicht zu 100 % überlappt, so dass der Abstand zwischen dem Netz und der Punktwolke berechnet werden musste. Diese Berechnung wurde mit CloudCompare durchgeführt. Nach der Bestimmung dieser Abstände wurde ein Abstandsschwellenwert von 2 festgelegt, um relevante Ergebnisse zu gewährleisten. Vor dem Entfernen von Nicht-Bodenpunkten zeigte die Punktwolke Gruppierungen mit einer großen Anzahl von Bodenpunkten am unteren Rand der Modelle (Abbildung II 1.8.8).




Abbildung II 1.8.8 Gruppierung von Bodenpunkten an der Basis des als Referenz verwendeten 3D-Modells

Nachdem die Punkte ausgewählt und exportiert worden waren, wurden mit ihnen geometrische Merkmalsberechnungen durchgeführt. Dieser Prozess lieferte einen weiteren wichtigen Satz von Informationen, die als Filterwerte verwendet werden konnten, um die Darstellung der Daten für diesen speziellen Bedarf zu verbessern. Durch die Verwendung verschiedener geometrischer Merkmale zur Eliminierung bestimmter Punkte konnte ein klareres Bild der Situation gewonnen werden. Dies ermöglichte ein besseres Verständnis der Probleme und Herausforderungen im Zusammenhang mit dieser Art von Daten.

Schließlich wurden die Ergebnisse validiert. Für den Berliner Datensatz führte ein Teammitglied (Studentische Hilfskraft) eine Vor-Ort- und On-Screen Informationserhebung (N=438) durch, um Vergleichsobjekte zur Bestimmung der Klassifikationsgenauigkeit zu erhalten. Für den Hamburger Datensatz wurde die Validierung anhand von RGB-Daten durchgeführt, die bereits in die Punktwolke eingebettet waren, ergänzt durch Google Earth. Dieser umfassende Validierungsansatz trug dazu bei, die Zuverlässigkeit der Ergebnisse zu bestätigen und lieferte wertvolle Einblicke in die Wirksamkeit der erstellten Methodik.

II 1.8.3 Ergebnisse

Die 6-monatige Arbeitsphase zu Methoden, um das Flächenpotential gebäudegebundener Vertical Farming Außenanlagen an Gebäuden unter der Nutzung von 3D-Stadtmodellen in Verbindung mit LiDAR Daten abzuschätzen, lieferte wertvolle Erkenntnisse und zeigte verschiedene Herausforderungen bei der Identifizierung geeigneter Strukturen für die vertikale Stadtbegrünung und das Vertical-Farming auf.

Durch den Vergleich der aus den Berliner und Hamburger Datensätzen gewonnenen Metriken sollten die Unterschiede zwischen den Datensätzen besser verstanden werden. Das Verständnis dieser Unterschiede in der Datenqualität und -abdeckung ist von entscheidender Bedeutung für die Bewältigung der spezifischen Herausforderungen in verschiedenen städtischen Umgebungen und die Verbesserung der Effektivität von Begrünungsmaßnahmen.

Zur Analyse der Punktwolkendaten wurde ein lokaler Nachbarschaftsradius von 1 festgelegt. Die Vertikalität der Punkte reicht von 0,59 bis 1. Die Hauptkomponentenanalyse (PCA) wurde durchgeführt, um die Variationen innerhalb des Datensatzes zu bestimmen. Die erste Hauptkomponente (PCA1), die die größte Variation aufweist, hat Werte zwischen 0,35 und 1, während die zweite Hauptkomponente (PCA2), die die zweitgrößte Variation zeigt, Werte zwischen 0 und 0,499 aufweist. Die Volumendichte der Punkte schwankt zwischen 0,955 und 6,923, die Oberflächendichte zwischen 1,273 und 9,231. Die Anzahl der Nachbarn für jeden Punkt reicht von 4 bis 29, wie in Abbildung II 1.8.2 zusammengefasst.

Abbildung II 1.8.2 Zusammenfassung der Metriken der Punktwolkenanalyse für Berliner Daten

Local neighborhood radius = 1	
Name	Value
Verticality	0.578 - 1
PCA1	0.355 - 1
PCA2	0 - 0.499
Surface Variation	0 - 0.308
Omnivariance	0 - 0.2317
Volume Density	0.955 - 6.923
Surface Density	1.273 - 9.231
Number of Neighbors	4 - 29

Für die Berliner Daten wäre es ideal, wenn das LiDAR einen klaren Weg hätte, um Strukturen genau zu erkennen. Die Analyse zeigte, dass nur einige große Gebäude und einige große Mauern erkannt wurden. In Gebieten wie dem Weitlingkiez ergaben kleinere Gebäude, die von Bäumen verdeckt waren, zu wenige Punkte, was die Erfassung erschwerte. Obwohl LiDAR die Vegetation durchdringen kann, gab es einfach nicht genug Punkte, um kleinere Strukturen genau zu erkennen (Abbildung II 1.8.9). Eine weitere Herausforderung war die hohe Gebäudedichte in einigen Teilen des Untersuchungsgebiets. Diese hohe Dichte führte zu Stellen in der Punktwolke, an denen entweder keine Daten oder nur wenige Punkte vorhanden waren, die für eine angemessene Analyse nicht ausreichten. Außerdem deuteten die Daten zwar darauf hin, dass einige Gebäude in Berlin für grüne Wände geeignet sein könnten, aber die Anzahl der Punkte reichte nicht aus, um diese Feststellung mit 100-prozentiger Sicherheit zu treffen.




Abbildung II 1.8.9 Verteilung der Punkte für die Analyse

In einem Teil Berlins, in dem sich überwiegend Hochhäuser befinden, war die Erkennung recht erfolgreich. Dieser Erfolg kann auf den klaren Pfad zurückgeführt werden, der für LiDAR-Strahlen in diesen Bereichen zur Verfügung steht. Es ist jedoch zu beobachten, dass nicht alle Seiten der Gebäude gleich gut erkannt werden und auch nicht den gleichen Detailreichtum aufweisen (Abbildung 10). Diese Diskrepanzen sind wahrscheinlich auf den Winkel zurückzuführen, in dem der LiDAR-Scanner die Daten erfasst hat, sowie auf die Flugrichtung des für die Datenerfassung verwendeten Schiffs. Die Ausrichtung und Position der Gebäude im Verhältnis zum Scanner wirkten sich auf die Qualität und Dichte der erfassten Punkte aus, was zu Unterschieden in der Erkennungsgenauigkeit der verschiedenen Fassaden führte (Abbildung II 1.8.11).




Abbildung II 1.8.10 Bereich in Berlin mit erfolgreicher Detektion




Abbildung II 1.8.11 Erkannte und als geeignet bestätigte Mauern

Während der Analyse gelang es der Methode, einige Wände zu erkennen, die für eine vertikale Begrünung geeignet erschienen (Abbildung II 1.8.11). Dennoch bleiben erhebliche Herausforderungen bestehen, insbesondere wenn die Ergebnisse nicht von einer Person überprüft werden (Abbildung II 1.8.12). Der automatische Erkennungsprozess identifizierte manchmal andere Formen als potenziell

geeignet für grüne Wände, aber diese Formen enthielten oft Fenster, so dass sie in Wirklichkeit ungeeignet waren. Dies unterstreicht, wie wichtig eine menschliche Überprüfung ist, um die Daten genau zu interpretieren und zu validieren und sicherzustellen, dass nur wirklich geeignete Flächen für städtische vertikale Begrünungsinitiativen in Betracht gezogen werden.




Abbildung II 1.8.12 Erkannte Mauern und Herausforderungen bei der Verifizierung

Wie bei den Berliner Daten wurde die Analyse der Punktwolke für Hamburg mit einem lokalen Nachbarschaftsradius von 1 Meter durchgeführt. Die Vertikalität der Punkte reicht von 0,84 bis 1. Die erste Hauptkomponente (PCA1) hat Werte zwischen 0,34 und 0,7, während die zweite Hauptkomponente (PCA2) Werte zwischen 0,3 und 0,499 aufweist. Die Volumendichte der Punkte schwankt zwischen 0,955 und 224,65, die Oberflächendichte zwischen 1,273 und 299,530. Die Anzahl der Nachbarn für jeden Punkt reicht von 4 bis 941, wie in Tabelle II 1.8.3 dargestellt.

Tabelle II 1.8.3 Zusammenfassung der Metriken der Punktwolkenanalyse für Hamburger Daten

Local neighborhood radius = 1	
Name	Value
Verticality	0.841 - 1
PCA1	0.344 - 0.704
PCA2	0.295 - 0.499
Surface Variation	0 - 0.318
Omnivariance	0.0001 - 0.2397
Volume Density	0.955 - 224.647
Surface Density	1.273 - 299.530
Number of Neighbors	4 - 941

Im Vergleich zu den Ergebnissen aus der Berliner Punktwolke ist zu beobachten, dass die Oberflächen- und Volumendichtewerte in den Hamburger Daten deutlich höher sind. Diese Diskrepanz kann auf die höhere Qualität der Hamburger Daten zurückgeführt werden. Auch die Anzahl der Nachbarn ist in den Hamburger Daten höher. Außerdem ist zu beachten, dass die verfügbaren Hamburger Daten ein viel kleineres Gebiet abdecken und im Vergleich zu den Berliner Daten homogener sind. Der Berliner Datensatz enthält eine Mischung aus verschiedenen Elementen, während die Hamburger Daten überwiegend einen stark urbanisierten Raum darstellen (Abbildung II 1.8.13). Diese Homogenität des

Hamburger Datensatzes führte möglicherweise zu einer besseren Gruppierung der Punkte, was zu den beobachteten Diskrepanzen zwischen den beiden Datensätzen führte.




Abbildung II 1.8.13 Interessengebiet in Hamburg nach Bearbeitung

In Anbetracht der Datendichte in Hamburg erwies es sich als effektiver für die Erkennung geeigneter Wände, obwohl es nicht ganz optimal war (Abbildung II 1.8.14). Das Vorhandensein von mehr Glasflächen führte zu Bereichen ohne Daten für die Analyse, aber in diesem Fall war dies hilfreich, da es die Eliminierung von Bereichen ermöglichte, die nicht geeignet waren.




Abbildung II 1.8.14 Mögliche Standorte für die Errichtung von grünen Wänden

Da das analysierte Gebiet relativ klein war, wurden nur wenige Gebäude mit geeigneten Wänden erkannt. Die Einbeziehung von RGB-Informationen in die Hamburger Daten erleichterte die genaue Beurteilung, ob die Methode geeignete Wände erkannte (Abbildung II 1.8.15). Die erkannte Wand war zwar größtenteils nutzbar, aber einige Strukturen am Gebäude würden die Nutzung der gesamten Wand verhindern. Dieses Beispiel unterstreicht den Wert von RGB-Daten für die Verbesserung der Genauigkeit von Erkennungs- und Überprüfungsverfahren.




Abbildung II 1.8.15 Erkannte geeignete Wand mit Verifizierung anhand von RGB-Daten

II 1.8.4 Schlussfolgerung

Während es empfohlene Lösungen für neue Gebäude und die Schaffung neuer Infrastrukturen für vertikale urbane Landwirtschaft gibt, war das Ziel dieser Arbeit, die Nutzung vorhandener Flächen in Städten zu untersuchen, die mit minimalen finanziellen Investitionen angepasst werden könnten. Durch die Identifizierung und Optimierung der Nutzung dieser vorhandenen Flächen sollten nachhaltige Initiativen zur Stadtbegrünung gefördert werden, ohne dass dafür umfangreiche Neubauten erforderlich sind. Ein weiteres Ziel war es, die Qualität und die Nutzung der vorhandenen LiDAR-Daten zu überprüfen.

Daten aus Berlin haben eine zu geringe Punktdichte, um hierzu belastbare Rückschlüsse ziehen zu können. Damit die entwickelte Methode zuverlässig angewendet werden kann, muss die vertikale Dichte der Punkte verbessert höher sein. Dies zeigen die BKG-Daten für Hamburg. Allerdings sind mit der höheren Punktdichte auch Herausforderungen zum Datenmanagement und Datenanalyse verbunden. Weitere Untersuchungen mit unterschiedlichen Punktdichten sind erforderlich, um die minimale und optimale Dichte zu bestimmen, die für eine genaue Erkennung erforderlich ist.

II 2 Die wichtigsten Positionen des zahlenmäßigen Nachweises

Die Personalkosten machen die wichtigste Position des zahlenmäßigen Nachweises aus.

Detaillierte Angaben liefert der zahlenmäßige Nachweis, der durch haushälterische Projektverwaltung erstellt und übermittelt wird.

II 3. Notwendigkeit und Angemessenheit der geleisteten Arbeit

Durch das Projekt HortiSem wurde der Zugriff und Informationsfluss für die Beratung und Produzenten verbessert. Mit HortiSem sind nach drei Projektjahren, Daten von BVL, PS-Info, EU-Pesticides Database, Warndienstmeldungen der Pflanzenschutzdienste und andere Informationsbasen über Schnittstellen maschinenlesbar analysier- und abfragbar. Dazu zählen Backlinks zur Datenbank des Bundesamtes für Verbraucherschutz und Lebensmittelsicherheit (BVL) ebenso wie die Verlinkungen zu den Notfallzulassungsbescheiden und Verknüpfungen zur „EU Pesticides Database“ mit den Rückstandshöchstgehalten sowie zu verschiedenen Wirkstoffdatenbanken. Auch eine Einbindung von hortigate in die Indikationssuche konnte realisiert werden.

II 4 Voraussichtlicher Nutzen, insbesondere der Verwertbarkeit des Ergebnisses im Sinne des fortgeschriebenen Verwertungsplans

Das Informationsportal PS INFO wurde weiterentwickelt, um als Linked Data-System für Pflanzenschutzinformationen andere relevante maschinenlesbare und recherchierbare Plattform Informationen zum Zulassungsstand, die damit verbundenen Auflagen und weiteren relevanten Informationen Dritter für den Einsatz von Pflanzenschutzmaßnahmen (EU Höchstmengen etc.) zu integrieren. Digital analysierbare Warndienstmeldungen können durch retrospektive Auswertung Kenntnisse zum Schaderregerauftreten verbessern. Systematische Analyse der Struktur und Semantik von Warndienstmeldungen der Länder ist erfolgt. Erkenntnisse können weiterverwendet werden. Austausch zur Weiterentwicklung im Projekt KIDA findet statt.

JKI wird diese Informationen nicht wirtschaftlich verwerten jedoch werden durch die Forschungsarbeiten zu NER- und LLM aktuelle Entwicklungen aufgegriffen, welche das JKI als Forschungspartner in diesem Bereich weiter stärkt, ebenso die Politikberatung in diesem Bereich. So wurde beispielsweise die Integration der Modelle in Kopplung mit dem Sprachmodell ChatGPT im Vorhaben untersucht (de Kock et al., 2023) und darauf aufbauend werden Forschungsskizzen vorbereitet.

II 5 Fortschritt auf dem Gebiet des Vorhabens anderer Stellen im Zuwendungszeitraum

Mit der Veröffentlichung von Chat-GPT Ende November 2022 ergeben sich stark erweiterte Möglichkeiten u.a. in der Verarbeitung natürlich-sprachlicher Texte. ChatGPT ist ein hochmodernes Sprachmodell, welches in der Lage ist, natürlich-sprachliche Texte zu verstehen und darauf basierende Antworten zu generieren. Es verwendet eine auf einem neuronalen Netz basierende Architektur, um große Mengen an Textdaten zu verarbeiten und daraus sinnvolle Erkenntnisse abzuleiten. Es erscheint sehr vielversprechend, in Hortisem entwickelte Modell mit den Möglichkeiten von ChatGPT zu koppeln. Im Falle historischer Warnmeldungen kann durch diese Kopplung der Umfang relevanter benannter Entitäten stark erweitert werden. Diese Möglichkeiten werden als weiterführende Forschungsthemen von JKI weiterverfolgt. Erste Ergebnisse dazu wurden noch in der Projektlaufzeit erzielt (de Kock et al. 2023).

II 6 Erfolgte und geplante Veröffentlichungen des Ergebnisses

Neben zahlreichen Tagungsbeiträgen aus dem Gesamtprojekt heraus wurden folgende Beiträge zum Teilvorhaben 4 JKI-Personal als Erst-, Zweit oder Letztautor veröffentlicht:

He-Bleinagel, Xia, Jung, Jascha Daniló, Golla, Burkhard (2022): Named Entity Recognition (NER) von Warndienstmeldungen im Gartenbau: Eine empirische Studie zu Design, Entwicklung und Bewertung

der statistischen und Deep-Learning benutzerdefinierten NER-Modelle. In: Tagungsband: 30. Deutsche Arbeitsbesprechung über Fragen der Unkrautbiologie und -bekämpfung. Julius Kühn-Institut. S. 360–365. (= Julius-Kühn-Archiv). Online unter:

https://www.openagrar.de/receive/openagrar_mods_00077231.

Jung, Jascha Daniló; **Xia He-Bleinagel**; Martini, Daniel; **Golla, Burkhard** (2022): Horticulture Semantic (HortiSem) – Natural Language Processing bei Entwicklung und Interaktion mit einem semantischen Netzwerk für die Landwirtschaft. 42. GIL-Jahrestagung, Künstliche Intelligenz in der Agrar- und Ernährungswirtschaft. Bonn: Gesellschaft für Informatik e.V.. PISSN: 1617-5468. ISBN: 978-3-88579-711-1. pp. 141-146. Tänikon, Online. 21.-22. Februar 2022. <https://dl.gi.de/items/22460501-bac5-4797-8da1-58136f06f6d5>

Arno de Kock, Xia He-Bleinagel, Jascha Daniló Jung, Daniel Martini, **Burkhard Golla** (2023): Design, Entwicklung und Bewertung von Named Entity Recognition (NER) und Large Language Models (LLM) am Beispiel von Warndienstmeldungen im Gartenbau.

Natural Language Processing (NLP) und Named-Entity-Recognition (NER) - Ein Kurzvideo (MP4) von Jascha Daniló Jung (KTBL) und **Xia He** (JKI) finden Sie auf hortigate:

<https://www.hortigate.de/publikation/93385/> (Länge: 4:43 min)

OpenAPI des NER Modells für Warndienstmeldungen unter <http://sf.julius-kuehn.de/hortisem/docs#>

Teil III Erfolgskontrollbericht (siehe Anlage)

IV Kurzfassung

Die Anforderungen an die gartenbauliche Beratung und Praxis im Bereich Pflanzenschutz sind zunehmend komplex geworden. Die Vielfalt der Kulturen und die Nutzung spezieller Regelungen stellen große Herausforderungen für die Datenbeschaffung und -verarbeitung dar. Um den rechtlichen Vorgaben gerecht zu werden, benötigen Akteure schnelle und einfache Zugänge zu relevanten Informationen, die sowohl für Menschen als auch für Maschinen lesbar sind. Idealerweise sollten zuverlässige und rechtssichere Datenbanken regional, national und europaweit vernetzt sein, etwa durch Linked-Data-Prinzipien.

Derzeit existieren jedoch nur isolierte Einzelsysteme wie die Online-Datenbank des BVL, PS Info, ISIP und hortigate. Ziel eines Verbundprojekts war es, praxisorientierte und funktionierende Linked-Data-Prinzipien zu demonstrieren, um gartenbauliche Praxisfragen zum Pflanzenschutz besser zu beantworten. Das System PS Info sollte als Beispiel dienen.

Ein Schwerpunkt war die Entwicklung eines Named Entity Recognition (NER) Modells zur Analyse von Warndienstmeldungen. NER identifiziert benannte Entitäten in Texten und ordnet sie Kategorien zu. Dafür wurden 114 Dateien mit 105.737 Wörtern analysiert und 9.019 Entitäten annotiert. Drei NER-Modelle basierend auf spaCy, Flair und CRF wurden trainiert, wobei spaCy mit einem F1-Wert von 0.8997 die höchste Genauigkeit erzielte. Geplant ist, das NER-Modell mit Large Language Models (LLMs) wie GPT-3.5 und GPT-4 zu kombinieren, um deren Kontextverständnis mit der präzisen Erkennung durch NER zu verbinden.

Zusätzlich wurde die Software zur Inventarisierung von Warndienstmeldungen (WMI) entwickelt, um die Ergebnisse verschiedener Interpretationsmethoden zu vergleichen. In einem weiteren Teilprojekt wurde der Mehrwert von Toxizitätsinformationen zu Pflanzenschutzmitteln (PSM) untersucht, wobei

die Integration im Projekt aufgrund Lizenz-rechtlicher Bedingungen nicht möglich war, jedoch technisch realisierbar ist.

Während der Aufstockungsphase des Projekts HortiSem-vertical wurden Methoden entwickelt, um das Flächenpotential gebäudegebundener Vertical-Farming-Anlagen unter Nutzung von 3D-Stadtmodellen und LiDAR-Daten zu ermitteln. Die Untersuchung ergab, dass LiDAR-Daten mit hoher Punktdichte (BKG-Daten des „Digitalen Zwillings Deutschland“) detaillierte Fassadenstrukturen erfassen können, um geeignete Bereiche für Vertical-Farming-Anlagen zu identifizieren. Das Julius Kühn-Institut steht für eine Weiterentwicklung der Methode in Kontakt mit dem Bundesamt für Kartographie und Geodäsie (BKG).

Literatur

- Arno de Kock, Xia He-Bleinagel, Jascha Daniló Jung, Daniel Martini, Burkhard Golla (2023): Design, Entwicklung und Bewertung von Named Entity Recognition (NER) und Large Language Models (LLM) am Beispiel von Warndienstmeldungen im Gartenbau.
- Al-Kodmany K. (2018), The Vertical Farm: A Review of Developments and Implications for the Vertical City, Buildings, 8, 24
- Andini M., Dewi O.C., Marwati A. (2021), Urban Farming During the Pandemic and Its Effect on Everyday Life, International Journal of Built Environment and Scientific Research, 5(1), 51-62
- Campbell N. (2017), Farming Cities: the Potential Environmental Benefits of Urban Agriculture, D.U.Quark, 2 (1), 3-16
- Despommier D., & Ellingsen E. (2008), The vertical farm: the sky-scraper as vehicle for a sustainable urban agriculture, CTBUH 8th World Congress on Tall & Green: Typology for a Sustainable Urban Future, 311-318
- Fai, S. & Rafeiro J. (2014), Establishing an Appropriate Level of Detail (LoD) for a Building Information Model (BIM) – West Block, Parliament Hill, Ottawa, Canada, ISPRS Ann. Photogramm. Remote Sens. Spatial Inf. Sci., II-5, 123–130
- Feldmann, Falko & Bloem, Elke & Dirksmeyer, Walter & Golla, Burkhard & Greef, Jörg & Piorr, Annette & Saltzmann, Jovanka & Vogler, Ute. (2023). Definition gebräuchlicher Begriffe der urbanen Landwirtschaft und englischer Entsprechungen. 10.5073/JfK.2023.01-02.02.
- Gustavsen G. W., Berglann H., Jenssen E., Kårstad S. & Rodriguez D.G.P. (2022), The Value of Urban Farming in Oslo, Norway: Community Gardens, Aquaponics and Vertical Farming, Int. J. Food System Dynamics, 13(1), 17-29
- Kalantari F., Mohd Tahir O., Akbari Joni R. & Fatemi E. (2018), Opportunities and challenges in sustainability of vertical farming: A review, Journal of Landscape Ecology, 11(1), 35-60
- Keong Ng A. & Mahkeswaran R. (2021), Emerging and Disruptive Technologies for Urban Farming: A Review and Assessment, *J. Phys.: Conf. Ser.*, 2003, 012008
- Lee J. & Chuang I. (2017), Living Green Shell: Urban Micro-Vertical Farm, International Journal of Applied Sciences (IJAS), 7(1), 1-16
- Manso M. & Castro-Gomes J. (2015), Green wall systems: A review of their characteristics, Renewable and Sustainable Energy Reviews, 41, 863-871
- Martin M., Weidner T., & Gullström C. (2022), Estimating the Potential of Building Integration and Regional Synergies to Improve the Environmental Performance of Urban Vertical Farming, Front. Sustain. Food Syst., 6, 849304

- Mok W.K., Tan Y.X., Chen W.N. (2020), Technology innovations for food security in Singapore: A case study of future food systems for an increasingly natural resource-scarce world. *Trends in Food Science & Technology*, 102, 155-168
- Pérez G., Escolà A., Rosell-Polo J.R., Coma J., Arasanz R., Marrero B., Cabeza L.F., Gregorio E. (2021), 3D characterization of a Boston Ivy double-skin green building facade using a LiDAR system, *Building and Environment*, 206, 108320
- Stanley M. H. & Debra F. Laefer D.F. (2021), Metrics for aerial, urban lidar point clouds, *ISPRS Journal of Photogrammetry and Remote Sensing*, 175, 268-281
- Thomaier S., Specht K., Henckel D., Dierich A., Siebert R., Freisinger U.B. & Sawicka M. (2015), Farming in and on Urban Buildings: Present Practice and Specific Novelties of Zero-Acreage Farming (ZFarming), *Renew. Agric. Food Syst.*, 30, 43–54
- Xi L., Zhang M., Zhang L., Lew T.T.S. & Lam Y.M. (2022), Novel Materials for Urban Farming, *Adv. Mater.*, 34, 2105009
- Zareba A., Krzeminska A., Kozik R. (2021), Urban Vertical Farming as an Example of Nature-Based Solutions Supporting a Healthy Society Living in the Urban Environment, *Resources*, 10, 109.

Sonstige Quellen

URL1: <https://www.un.org/en/global-issues/population> (10.06.2024)

URL2: <https://www.unccd.int/news-stories/stories/world-cities-day-2020-better-city-better-life> (10.06.2024)

URL3: https://osmbuildings.org/blog/2018-02-28_level_of_detail (12.06.2024)