

Experimentelle Entwicklung einer modellbasierten prädiktiven Regelung für den flexiblen Betrieb von Biogasanlagen

Dissertation zur Erlangung des Grades eines Doktors der Agrarwissenschaften
(Dr. sc. agr.)

Fakultät Agrarwissenschaften
Universität Hohenheim

Landesanstalt für Agrartechnik und Bioenergie

vorgelegt von
M. Eng. Celina Dittmer
von Fehmarn

Stuttgart-Hohenheim
2022

Die vorliegende Arbeit wurde am 16. November 2022 von der Fakultät Agrarwissenschaften der Universität Hohenheim als „Dissertation zur Erlangung des Grades eines Doktors der Agrarwissenschaften“ angenommen.

Leiter des Kolloquiums: Prof. Dr. Jörn Bennewitz

Berichtersteller, 1. Prüfer: PD Dr. Andreas Lemmer

Mitberichtersteller, 2. Prüfer: Prof. Dr. Bernd Thomas

3. Prüfer: Prof. Dr. Joachim Müller

Tag der mündlichen Prüfung: 21. April 2023

Alle Rechte vorbehalten. Die Verwendung von Texten und Bildern, auch auszugsweise, ist ohne Zustimmung des Autors urheberrechtswidrig und strafbar. Das gilt insbesondere für Vervielfältigung, Übersetzung, Mikroverfilmung sowie die Einspeicherung und Verarbeitung in elektronischen Systemen.

© 2023 Celina Dittmer

Im Selbstverlag: Celina Dittmer

Bezugsquelle: Universität Hohenheim

Landesanstalt für Agrarwissenschaften

D-70599 Stuttgart

Danksagung

Die hier vorliegende Dissertation entstand in einer Zeit, in der bis dato unvorstellbare Krisen wie die Corona-Pandemie und der Ukraine-Krieg die Welt erschütterten. Wichtiger denn je, erschien mir mein großes Anliegen, einen Beitrag für die Umsetzung der Energiewende als Maßnahme gegen die verheerendste Krise, den Klimawandel, zu erbringen. Mit dieser Motivation widmete ich mich dieser Arbeit.

Mein besonderer Dank gilt Herrn PD Dr. Andreas Lemmer für die Annahme als Doktorandin. Ich möchte mich für die hervorragende fachliche Unterstützung, die vielen Ideen und neuen Blickwinkel und die kompetente und kritische Begleitung bei der Ausarbeitung der vorliegenden Arbeit bedanken. Außerdem möchte ich meinen herzlichen Dank für das durchweg große Verständnis und die Unterstützung hinsichtlich der Vereinbarkeit von Familie und Promotion aussprechen.

Herrn Prof. Dr. Bernd Thomas möchte ich für die Übernahme des Zweitgutachtens und die vielen hilfreichen Ratschläge, Rückmeldungen und zielführenden Diskussionen im Rahmen unserer Projekttreffen für „PowerLand 4.2“ danken.

Mein Dank gilt außerdem Herrn Prof. Dr. Joachim Müller für die Übernahme des Drittgutachtens sowie die Mitwirkung an der mündlichen Prüfung.

Einen weiteren besonderen Dank richte ich an Herrn Dr. Johannes Krümpel dessen kritische Begleitung und fachlich sehr kompetente Unterstützung maßgeblich zum Erfolg dieser Arbeit beigetragen haben. Insbesondere von seinem Wissen in den Bereichen der Programmierung und Datenverarbeitung konnte ich enorm profitieren.

Ein herzliches Dankeschön geht zudem an den Leiter Herrn Dr. Hans Oechsner sowie allen Mitarbeiterinnen und Mitarbeitern der Landesanstalt für Agrartechnik und Bioenergie für die Bereitstellung hervorragender Forschungs- und Arbeitsbedingungen. Von ihnen konnte ich fachlich aber auch persönlich wertvolle Unterstützung, Hilfsbereitschaft und eine immerzu angenehme Arbeitsatmosphäre erfahren. Ich wünsche ihnen allen nur das Beste!

Den Mitarbeitern des Standortes „Unterer Lindenhof“, zuständig für den Betrieb der Biogasanlage, möchte ich ebenfalls für ihre Hilfsbereitschaft danken. Ich habe mich immer gefreut, wenn ich bei ihnen ein bisschen „Biogas schnuppern“ gehen konnte.

Abschließend richte ich meinen größten Dank an meine Familie, meine Eltern und Geschwister und insbesondere an meinen Partner Yves Muheim und unseren Sohn Jakob. Ihre bedingungslose Unterstützung und ihr moralischer Beistand gaben mir die notwendige Zeit, die Kraft und den Mut für die Fertigstellung dieser Dissertation. Unserem Sohn Jakob, dessen Geburt in die Zeit meiner Promotion fiel, widme ich diese Ausarbeitung. Ich werde mich immer daran erinnern, wie ich mit einer Hand tippte, während er in dem anderen Arm schlummerte.

Inhaltsverzeichnis

1. Einleitung	1
1.1 Hintergrund.....	1
1.2 Flexibler Biogasanlagenbetrieb	3
1.2.1 Stromprognosen	4
1.2.2 Modellierung Biogasproduktion	6
1.3 Zielsetzung	8
2. Publikation 1: Power demand forecasting for demand-driven energy production with biogas plants.....	9
Abstract.....	10
3. Publikation 2: Modeling and Simulation of Biogas Production in Full Scale with Time Series Analysis	18
Abstract.....	19
4. Publikation 3: Model Predictive Control: Demand-orientated, Load-flexible, Full-scale Biogas Production.....	29
Abstract.....	30
5. Gesamtdiskussion	45
5.1 Modellprädiktive Regelung	45
5.1.1 Simulationsmodell Biogasproduktion	49
5.1.2 Berechnung der Fütterungspläne, Controller	54
5.2 Schlussfolgerungen und Ausblick.....	56
6. Zusammenfassung	60
7. Summary	62
Referenzen	64

1. Einleitung

1.1 Hintergrund

Die Energieversorgung macht den größten Anteil an den globalen Treibhausgasemissionen aus, deren Stabilisation auf einem niedrigeren Niveau aufgrund des stetig voranschreitenden Klimawandels unerlässlich ist. Erforderlich ist eine grundlegende Transformation des Energiesystems einschließlich der langfristigen Substitution fossiler Energieträger durch erneuerbare Energien [1]. Mit Beginn des russischen Angriffskrieges auf die Ukraine im Februar 2022 rückt zudem der Anspruch nach Unabhängigkeit von Importen fossiler Energieträger stark in den Fokus, was ebenfalls einen beschleunigten Ausbau der Nutzung alternativer Energiequellen in Deutschland und der Europäischen Union bedingt [2]. Mit dieser Veranlassung verabschiedete die deutsche Bundesregierung im April 2022 das Energiesofortmaßnahmenpaket („Osterpaket“), welches den Grundsatz verankert, „dass die Nutzung erneuerbarer Energien im überragenden öffentlichen Interesse liegt und der öffentlichen Sicherheit dient“ [3]. Die Ausbauziele wurden in diesem Zuge massiv angehoben, sodass von derzeit 42 % des Bruttostromverbrauchs (Stand 2022) bis zum Jahr 2030 mindestens 80 % über erneuerbare Energien gedeckt werden sollen. Dafür erweitern sich die Ausbaupfade bis 2030 dahingehend, dass Windenergie an Land im Umfang von 115 GW installiert sein soll und Photovoltaikanlagen (PV) sollen mit einer Gesamtleistung von rund 215 GW betrieben werden [4]. Langfristig gesehen, werden entsprechend Wind- und PV-Anlagen den Großteil der Stromversorgung sicherstellen. Herausfordernd gestaltet sich die hohe Abhängigkeit dieser Produktionsleistungen von den vorherrschenden Witterungsbedingungen.

Durch den Ausbau der stark fluktuierenden Stromerzeugung auf Basis der Windkraft und Photovoltaik gewinnt der Ausgleich zwischen Bedarf und Erzeugung zunehmend an Bedeutung. Dieser Ausgleich setzt die fortwährende Kenntnis des Bedarfs von einer sehr großen Anzahl an Stromnutzern und der Produktion einer Vielzahl von dezentralen Erzeugungsanlagen voraus. Folglich ist eines der elementarsten Werkzeuge des zukünftigen Energiesystems die Informationstechnologie und damit die Digitalisierung. Sie bietet die Voraussetzung die schwankenden Erzeugungen transparent und damit planbarer zu machen, Energieflüsse durch Abstimmung von Erzeugungs- und Verbraucherseite zu steuern sowie die Sektorenkopplung zwischen verschiedenen Energiebereichen zu ermöglichen [5]. Rechtlich manifestiert wurde die „Digitalisierung der Energiewende“ im Kontext des 2009 in Kraft

getretenen EU-Binnenmarktpakets „Energie 2009/72/EG“ [6]. Es beinhaltet im Wesentlichen den verpflichtenden Einbau intelligenter Messsysteme sowohl für Stromproduzenten als auch für –verbraucher. Die sogenannten Smart Meter ermöglichen in Verbindung mit einer Kommunikationseinheit (Smart Meter Gateway) eine permanente Erfassung, Verarbeitung und Übertragung von Energiedaten. Seit Februar 2020 hat die Umstellung bisheriger Messsysteme auf Smart Meter, kombiniert mit -Gateways, gesetzlich verpflichtend begonnen [7]. Damit werden entscheidende Voraussetzungen geschaffen, um Flexibilität zum Ausgleich zeitlicher Disparitäten zwischen Stromerzeugung und –verbrauch gezielt und effizient einsetzen zu können [8].

Schätzungen zufolge wird bei einem Anteil von über 90 % erneuerbarer Energien an der Bruttostromproduktion in Deutschland eine flexible Leistung von 60 bis 70 GW zur Deckung des Residuallastbedarfs notwendig [9]. Eine weitere Studie [10] beziffert die notwendige Kapazität regelbarer Stromerzeuger sogar mit 100 bis 150 GW. Diese Leistung kann teilweise durch die Nutzung von Stromspeichern sichergestellt werden. Deren Ausbau ist jedoch aus technischen und ökonomischen Gründen begrenzt [11]. Zudem geht die Speicherung von Strom immer aufgrund der Konversionsschritte mit einem Effizienzverlust einher [12]. Ein durch Hartmann et al. (2013) [13] durchgeführter Vergleich der Wirkungsgrade vielfach genutzter Stromspeicher zeigt, dass Batteriespeicher mit 90% den höchsten Wirkungsgrad aufweisen. Pumpspeicherkraftwerke, die seit Jahrzehnten im großem Maßstab kommerziell genutzt werden, haben jedoch nur Wirkungsgrade von ca. 80%, Druckluftspeicher kommen sogar nur auf maximal 60% [13]. Umso entscheidender erweist sich die Nutzung von flexiblen Kraftwerken zur bedarfsorientierten Stromproduktion. Neben Technologien in den Bereichen Wasserkraft und Geothermie bietet bisher nur die Bioenergie eine Möglichkeit zur flexiblen Stromproduktion auf Basis erneuerbarer Energien [14]. Das Erneuerbare-Energien-Gesetz 2023 (EEG) sieht in diesem Zusammenhang vor, dass „die Förderung der Biomasse stärker auf hochflexible Spitzenlastkraftwerke fokussiert wird, damit die Bioenergie ihre Stärke als speicherbarer Energieträger zunehmend systemdienlich ausspielen kann und einen größeren Beitrag zu einer sicheren Stromversorgung leistet“ [4].

Der Betrieb von Biogasanlagen in Kombination mit Blockheizkraftwerken (BHKW) kann den Ausgleich sowohl langfristiger saisonaler als auch kurzfristiger Schwankungen in der Stromeinspeisung sichern. Derzeit steuert das Biogas 13 % der gesamten erneuerbaren

Stromerzeugung bei [15]. Werden alle Potentiale zur flexiblen Strombereitstellung der rund 9000 Biogasanlagen, die dezentral über Deutschland verteilt installiert sind, ausgeschöpft, dann können bis zu 30 GW flexible Spitzenleistung bereitgestellt werden [16].

1.2 Flexibler Biogasanlagenbetrieb

Die Stromproduktion mittels Biogasanlagen kann als ausgleichendes Element gegenüber fluktuierenden Stromerzeugern dienen. Inwieweit dieser Ausgleich gelingt, hängt maßgeblich von dem Grad der Flexibilität des Biogasanlagenbetriebes ab. Mit Beginn des 21. Jahrhunderts bedingte die Ausgestaltung von Fördermodellen des EEG, dass Biogasanlagen ausschließlich einen Anteil der Grundlastversorgung stellten. Die fixe Vergütung pro eingespeiste Kilowattstunde hielt die Betreiber dazu an, möglichst viel Strom zu produzieren und unabhängig von dem jeweiligen Energiebedarf einzuspeisen. Mit der Einführung der sogenannten „Flexibilitätsprämie“ im EEG des Jahres 2012 wurden erstmals Anreize für eine bedarfsorientierte Stromproduktion gesetzt [17]. Die notwendigen technischen Anpassungen beliefen sich in erster Linie auf den Ausbau der Gasspeicherkapazitäten [18], die Installation von BHKW größerer Leistungsklassen sowie die Erhöhung der Anschlussleistung des Transformators [19]. Damit lässt sich kurzfristig eine bedarfsorientierte Stromproduktion gewährleisten, indem das produzierte Biogas zu Zeiten geringen Strombedarfs gespeichert und anschließend bei erhöhtem Bedarf in größerer Menge verstromt wird. Aufgrund kosten-, sicherheitstechnischen und genehmigungsrechtlichen Aspekten ist der Ausbau der Gasspeicher und damit das Ausmaß der Flexibilität jedoch beschränkt [20]. Die Verlagerung des Stromerzeugungspotentials kann einzig über Stunden, kaum aber über mehrere Tage ermöglicht werden. Die Ergebnisse der Kostenanalyse von Hahn et al. (2014) [21] bestätigen, dass Biogasspeicher-Konzepte lediglich sinnvoll einsetzbar sind, wenn eine flexible Stromproduktion über maximal 8 Stunden pro Tag bereitgestellt werden muss.

Eine deutlich höhere Flexibilität in der Strombereitstellung durch Biogasanlagen kann erreicht werden, indem bereits die Konversion der Biomasse zu Biogas bedarfsgerecht erfolgt. Dies resultiert aus einem gezielten Fütterungsmanagement. Die Studie von Mauky et al. (2017) [18] zeigt hierzu, dass durch Anwendung eines Fütterungsmanagements hohe Einsparpotentiale hinsichtlich der erforderlichen Gasspeicherkapazitäten von bis zu 45 % gegenüber einer konstanten Biogasproduktion möglich sind, woraus eine weitaus größere Flexibilität bei der Stromproduktion resultiert. Zudem konnte das Potential einer Stromabschaltung über drei Tage aufgezeigt werden, bei der sich die Gasproduktion um mehr

als 60 % verringerte. In Vogel et al. (2018) [20] konnten diese Ergebnisse sogar übertroffen werden, indem eine Verstromungspause von 60 Stunden im großtechnischen Maßstab gewährleistet wurde und 50 % des Gasspeicherbedarfs gegenüber einem Betrieb mit kontinuierlicher Gasproduktion eingespart wurde. Die Ergebnisse von Grim et al. (2015) [22] zeigen, dass durch das Fütterungsmanagement die Kosten für den Gasspeicherausbau um 24 bis 53 % reduziert werden konnten und somit wirtschaftliche Szenarien einer bedarfsgerechten Stromproduktion überhaupt erst möglich werden. Im Kontext der Wirtschaftlichkeit sollte auch die Nutzung der parallel produzierten thermischen Energie Beachtung finden. Dass bei einem bedarfsorientierten und damit unsteten Betrieb des BHKW die erzeugte Wärme nicht zwangsläufig ungenutzt bleiben muss, zeigen Maier und Thomas (2022) [23,24], indem die Kombination aus Wärmespeichern und einem intelligenten BHKW-Management die nahezu vollständige Nutzung der produzierten Wärme ermöglicht und sich damit die Energieeffizienz der Biogasanlage deutlich erhöht.

Neben den bedeutenden Vorteilen stellt sich bei der Umsetzung des Fütterungsmanagements die große Herausforderung der mehrtägigen Gasbildungskinetik im Fermentationsprozess, die zudem außerordentlich abhängig von den Prozessbedingungen ist [25,26]. Dieser Umstand macht es erforderlich, dass die Planung der Substratzugabe vorausschauend erfolgen muss. Daraus resultieren im Wesentlichen zwei Anforderungen, um eine bedarfsorientierte Biogasproduktion gewährleisten zu können: 1) Es muss eine Prognose des Strombedarfs erfolgen, um ein vorausschauendes Fütterungsmanagement gewährleisten zu können. 2) Der Prozess der Biogasproduktion in einer großtechnischen Biogasanlage muss modelliert werden, um die Fütterungen so justieren zu können, dass eine bedarfsgerechte Biogasproduktion erfolgen kann.

1.2.1 Stromprognosen

Prognosen für den Energiebedarf und die Strom- und Wärmeerzeugung dienen in der Energiewirtschaft als essentielle Werkzeuge um Energieflüsse planbar zu machen, Risiken zu minimieren und Kosten zu sparen [27,28]. Insbesondere Stromhändler und Netzbetreiber sind auf Stromprognosen angewiesen, um Produktion und Bedarf aufeinander abstimmen zu können. Während das konventionelle Stromsystem lediglich eine Prognose des Strombedarfs notwendig machte, sind mittlerweile Prognosen über die Stromproduktion wetterabhängiger, nicht regelbarer Kraftwerke ebenso unerlässlich [29]. Je nach Anwendung kommen unterschiedliche Prognosehorizonte und damit –modelle zum Einsatz. Langfristige Prognosen

über mehrere Jahre können beispielsweise Investitionsentscheidungen und der Planung von Kraftwerkskapazitäten zugrunde gelegt werden. Der Handel von Strom auf Terminmärkten macht eine Prognose über mehrere Wochen notwendig, auf Spotmärkten müssen Stromflüsse kurzfristig über wenige Stunden vorhergesagt werden. Sehr kurzfristig werden Regelernergie und Systemdienstleistungen bereitgestellt, weshalb eine Vorhersage der kommenden Minuten oder nur Sekunden erfolgt [30].

Die Auswahl eines Vorhersageverfahrens wird zudem über den Anspruch an die Qualität der Prognose sowie über die Verfügbarkeit historischer Daten bestimmt [31]. In diesem Zusammenhang wird die große Bedeutung der zunehmenden Digitalisierung des Energiesystems sichtbar. Frühere Strommärkte basierten auf quasistationären Verbrauchs- und Erzeugerstrukturen, deren konsistente, historische Datenbasis weitestgehend bekannt war [31]. Zudem lassen sich kumulierte Lasten von großen Einzugsgebieten in der Regel einfacher prognostizieren als beispielsweise der Strombedarf kleinteiliger Gebiete oder einzelner Haushalte [32]. Neue Ansprüche an die Stromprognosen sehen jedoch zunehmend die Vorhersage von Produktionen einzelner Anlagen und dem Verbrauch kleiner Regionen bis hin zu einzelnen Verbrauchern vor, um so zu einer effizienten, dezentralen Strombereitstellung beitragen zu können [32]. Dies könnte auch der Versorgungseinheit einer Biogasanlage entsprechen, für deren angepassten Betrieb der Strombedarf ländlicher Regionen mit wenigen Verbrauchseinheiten relevant ist. Notwendig wird diesbezüglich eine ausreichende Datenbasis, die zum Teil über den Einbau der Smart Meter gewährleistet werden kann. Zum anderen müssen geeignete Prognosemodelle evaluiert werden, die den neuen Aufgaben gerecht werden können.

In diesem Kontext wurde in Bennett et al. (2014) [33] ein Methodenvergleich zwischen der Zeitreihenanalyse und einem neuronalen Netz zur Vorhersage des Strombedarfs von 128 Haushalten getätigt. Die Zeitreihenanalyse ist ein vielgenutztes und sehr leistungsfähiges Werkzeug und gehört zu den klassischen Prognoseverfahren. Es basiert im Wesentlichen darauf, dass mittels mathematischer Modelle die zurückliegende zeitliche Entwicklung zur Vorhersage zukünftiger Entwicklungen genutzt werden kann. Vorwiegend verwendet werden autoregressive Modelle (AR-Modell) und deren Erweiterungen, das Auto-Regressive Moving Average (ARMA) Modell und das Auto-Regressive Integrated Moving Average (ARIMA) Modell, welche Korrelationen und Saisonalitäten in der Zeitreihe analysieren und diese für die

Berechnung einer Vorhersage nutzen [34]. Künstliche neuronale Netze gehören hingegen zu den nichtlinearen Regressionsmodellen und verfügen damit über den einmaligen Vorteil, nicht lineare Zusammenhänge darstellen zu können [35]. Nachteilig erweist sich jedoch, dass ein aufwendiges Training des Netzes erfolgen muss, was zeitintensiv ist und umfangreiche Datensätze erforderlich macht. Die Ergebnisse von Bennett et al. (2014) [33] zeigen eine geringfügig bessere Qualität der Prognosen mittels neuronalen Netzen gegenüber denen der Zeitreihenanalyse. Dabei wurde ein Prognosehorizont von 24 Stunden gewählt. In Tidemann et al. (2013) [36] wird ebenfalls ein Methodenvergleich für die Stromprognose von 150 Haushalten über 24 Stunden vorgenommen. Hier fallen die Ergebnisse der Zeitreihenanalyse (AR-Modell) hingegen besser als die des neuronalen Netzes aus. Auch in Sevlian et al. (2014) [37] zeigen sich bei der Evaluation von Prognoseverfahren für die Stromvorhersage einer steigenden Anzahl an Haushalten die Modelle der Zeitreihenanalyse (ARMA-Modell) durchweg bessere Ergebnisse als bei neuronalen Netzen. Zudem kann deutlich nachgewiesen werden, dass sich mit steigender Anzahl an Haushalten die Qualität der Prognoseergebnisse verbessert.

Konkret zur Ausrichtung des residuallastangepassten Betriebs von Biogasanlagen bestehen Anforderungen an Prognoseverfahren hinsichtlich des Prognosehorizontes, der einer mehrtägigen Gasbildungskinetik gerecht werden muss, sowie hinsichtlich der Prognosequalität, da Abweichungen des vorhergesagten Strombedarfs durch den Gasspeicher kompensiert werden müssen. Evaluationen von Prognoseverfahren mit dem Ziel einer Sollwertbestimmung zur Ausrichtung der Biogasproduktion und unter Berücksichtigung dieser spezifischen Anforderungen wurden bisher noch nicht durchgeführt.

1.2.2 Modellierung Biogasproduktion

Entwicklungen zur Modellierung der anaeroben Fermentation begannen bereits in den frühen 1970er Jahren, in denen das Wissen über den komplexen Prozess der Vergärung sowie die Rechenleistungen der Computer jedoch noch eingeschränkt waren [38]. Diese ersten, sehr simplen Modelle, entwickelten sich in den letzten Jahrzehnten zunehmend weiter, sodass die Simulation der Biogasproduktion mittlerweile auf äußerst umfangreichen, komplexen Modellen beruht. Donoso et al. (2011) [39] beschreibt in diesem Zuge das Anaerobic Digestion Model No.1 (ADM1) als einen der zweifelslos größten Meilensteine dieser Forschungsära. Ausführlich dargelegt durch Batstone et al. (2013) [40], wurde das ADM1 1997 von der International Water Association (IWA) mit der Veranlassung entwickelt, ein standardisiertes

Verfahren zur Modellierung sämtlicher anaerober Prozesse zu schaffen. Die Literatur zeigt mannigfache Untersuchungen, in denen das ADM1 als Basis zur Modellierung des Biogasprozesses dient. Bis dato finden sich jedoch nur wenige Exempel für dessen praktischen Einsatz in großtechnischen Biogasanlagen. In Lübken et al. (2007) [41] beispielsweise, wird die Biogasproduktion und –zusammensetzung mittels ADM1 im Pilotmaßstab simuliert, um Kenntnis über die Nettoenergieproduktion zu erhalten und damit eine Effizienzsteigerung der Biogasanlage zu erzielen. Die Anwendbarkeit eines erweiterten ADM1-Modells auf die Monovergärung von lignozellulosehaltiger Biomasse, wie Grassilage, wurde zudem im Rahmen der Untersuchungen von Koch et al. (2010) [42] evaluiert. In Biernacki et al. (2013) [43] dient das ADM1 wiederum einer Vorhersage der Biogasbildungskinetik von komplexen Substraten wie Gras-, Mais- und Grünkräutersilage sowie Industrieglyzerin. Die Publikation von Hagos et al. (2017) [44] weist das ADM1 und seine Modifikationen generell als das leistungsfähigste Werkzeug für Optimierungszwecke des Biogasprozesses aus. Insgesamt kann identifiziert werden, dass die Zielsetzung der Modellierung des Biogasprozesses bisher meistens der Prozesskontrolle oder zu Steuerungszwecken diene. Eine Übersicht der Anwendungen des ADM1 sowie weiterer Methoden der Modellierung und deren Zielsetzungen sind ausführlich in den Reviews von Lauwers et al. (2013) und Gavala et al. (2003) [38,45] dargelegt. Konkret im Zuge eines Fütterungsmanagements zur bedarfsorientierten Biogasproduktion nutzen Grim (2015), Mauky (2016) und Peters et al. (2019) [22,46,47] das ADM1 zur Modellierung des Prozesses.

Einer der Hauptnachteile komplexer Modelle wie das ADM1 zeigt sich in der großen Anzahl an benötigten Modellparametern und den Schwierigkeiten bei der Identifikation dieser [39]. Hinsichtlich der Stöchiometrie und der Kinetik einzelner Substrate sind Abschätzungen aus experimentellen, anlagenindividuellen Daten notwendig. Ergebnisse aus Laborversuchen lassen sich jedoch oftmals nur unzureichend auf großtechnische Biogasanlagen übertragen, da diese kontinuierlich betrieben werden und somit hinsichtlich der Populationsdichte der Mikroorganismen und der Zusammensetzung der mikrobiellen Gemeinschaft sowie der Substratverfügbarkeit gänzlich andere Bedingungen aufweisen [20]. Zudem stellt es sich als schwierig bis unmöglich dar, die spezifischen Biomasse-Konzentrationen aus dem zugeführten Substratmix einer großtechnischen Biogasanlage kontinuierlich zu ermitteln [39]. Die weiterhin notwendigen Messungen von Schlüsselparametern an der Biogasanlage setzen überdies die Installation sehr präziser und finanziell aufwendiger Messtechnik voraus. Dem

gegenüber steht, dass Biogasanlagen oftmals nur sehr rudimentär mit Mess-, Steuerungs- und Regeltechnik ausgestattet sind. Gaida et al. (2017) [48] fassen in einem Review zu Methoden des Fütterungsmanagements die folgenden drei größten Herausforderungen zusammen: 1) Es müssen finanzierbare und wartungsarme Messsysteme zur Aufnahme der wichtigsten Prozessvariablen vorhanden sein. 2) Das Modell muss mit einer hohen Anzahl an unterschiedlichen Substraten funktionieren können. 3) Es sind erfolgreiche, praktische Anwendungsbeispiele auf großtechnischen Biogasanlagen notwendig.

Um zukünftig eine bedarfsorientierte Biogasproduktion großtechnischer Anlagen realistisch und im großen Maßstab umsetzbar machen zu können, wird entsprechend ein praxistaugliches Fütterungsmanagement-Modell erforderlich. Bislang ist noch kein Modell entwickelt worden, welches den Umständen in der Weise gerecht werden kann.

1.3 Zielsetzung

Die Transformation des elektrischen Energiesystems von einer auf fossilen Energien beruhenden Erzeugung zu einem System, das auf erneuerbaren Energien basiert, macht aufgrund zunehmend dezentraler, fluktuierender Stromeinspeisungen regelbare Produzenten dringend erforderlich. Biogasanlagen bergen diesbezüglich enormes Potential, sofern eine größtmögliche Flexibilisierung des Anlagenbetriebes und Integration in das komplexe Energiesystem erfolgt.

Zielsetzung dieser Arbeit ist die experimentelle Entwicklung einer modellbasierten prädiktiven Regelung des Biogasanlagenbetriebes für eine optimale bedarfsgerechte Stromproduktion. Die in einem Reallabor der Universität Hohenheim („Unterer Lindenhof“) erarbeiteten Ergebnisse sollen die unmittelbare Adaption der Modelle in die Praxis aufzeigen. Diese modellprädiktive Regelung setzt die Entwicklung folgender Einzelkomponenten voraus.

- Modell zur Prognose des Strombedarfs des Reallabors
- Modell zur Simulation der Biogasproduktion
- Gesamtmodell zur Fütterungsplanung für eine bedarfsgerechte Biogasproduktion

Die Resultate aller Entwicklungen und Untersuchungen sind in drei Artikeln publiziert worden, welche im Folgenden dargelegt sind. Eine gesamtheitliche Diskussion dieser, sowie eine Zusammenfassung schließen diese Arbeit ab.

2. Publikation 1: Power demand forecasting for demand-driven energy production with biogas plants

Celina Dittmer^a, Johannes Krümpel^a, Andreas Lemmer^a

^a *Landesanstalt für Agrartechnik und Bioenergie, Universität Hohenheim, Garbenstrasse 9, 70599 Stuttgart, Germany*

Informationen Publikation:

Publiziert: Renewable Energy, Volume 162, Seiten 1871-1877

Empfangen: 4. Juni 2020

Akzeptiert: 23. Oktober 2020

DOI: 10.1016/j.renene.2020.10.099

Online: seit 27. Oktober 2020 unter <https://doi.org/10.1016/j.renene.2020.10.099>

Abstract


For the future energy system it becomes increasingly important that biogas plants produce electricity in a demand-oriented way to compensate electricity production from fluctuating sources like wind power and photovoltaics. Flexibilisation concepts provide a coordinated feeding management, which consider different gas production kinetics of used substrates to adjust the biogas production. To enable the generation of a prospective timetable, suitable forecast models for power demand were evaluated. The resulting 48-hour forecasts of power demand of a representative region (“real-world laboratory”) demonstrated that the four selected models achieve comparably good results with a mean absolute percentage error (MAPE) between 13-16%. Further evaluation showed that forecasts over longer periods of up to 14 days are advantageous as they are possible without compromising forecast quality.

Key words: Time Series Analysis; Prediction; Feeding management; demand orientated biogas; ARIMA; TBATS



Contents lists available at ScienceDirect

Renewable Energy

journal homepage: www.elsevier.com/locate/renene

Power demand forecasting for demand-driven energy production with biogas plants

Celina Dittmer, Johannes Krümpel*, Andreas Lemmer

State Institute of Agricultural Engineering and Bioenergy, University of Hohenheim, Garbenstrasse 9, 70599, Stuttgart, Germany

ARTICLE INFO

Article history:

Received 4 June 2020

Received in revised form

2 September 2020

Accepted 23 October 2020

Available online 27 October 2020

Keywords:

Time series analysis

Prediction

Feeding management

Demand-orientated biogas

ARIMA

TBATS

ABSTRACT

For the future energy system it becomes increasingly important that biogas plants produce electricity in a demand-oriented way to compensate electricity production from fluctuating sources like wind power and photovoltaics. Flexibilisation concepts provide a coordinated feeding management, which consider different gas production kinetics of used substrates to adjust the biogas production. To enable the generation of a prospective timetable, suitable forecast models for power demand were evaluated. The resulting 48-h forecasts of power demand of a “real-world laboratory” demonstrated that the four selected models achieve comparably good results with a mean absolute percentage error (MAPE) between 13 and 16%. Further evaluation showed that forecasts over longer periods of up to 14 days are advantageous as they are possible without compromising forecast quality.

© 2020 The Authors. Published by Elsevier Ltd. This is an open access article under the CC BY license (<http://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Worldwide, there is an urgent need to change the energy supply from non-renewable to renewable energy resources [1]. The targets of the European Union have even been made stricter in 2018, increasing the share of energy from renewable resources from initially 27% to at least 32% by 2030 [2]. Wind power and photovoltaics (PV) will provide the majority of the future electricity supply, due to high efficiencies and the lowest energy production costs of 3.71–11.54 €/Cents/kWh for PV and 3.99 to 8.23 €/Cents/kWh for onshore wind power [3]. However, this electricity production is characterised by strong fluctuations because of its dependence on weather conditions [4]. Therefore, it is essential to balance electricity production and consumption, which will be achieved by two approaches. On one hand, consumers should comprehend and engaged to assume a new role as active participants in the electricity system by partly adjusting their consumption (demand-side management) [5]. On the other hand, a higher importance will be placed on load-flexible and modular energy production.

“Of the available renewable energy technologies – besides

geothermal plants and hydropower stations – bioenergy plants in general and biogas plants in particular, currently enable electricity production to be controlled” [6]. In order to ensure controllable electricity production using biogas plants, on-site gas storage capacities can be expanded to allow short-term decoupling of electricity production in the combined heat and power plant (CHP) from gas production. Thus, the stored biogas can be converted into electricity and heat when demand arises. Nevertheless, this upgrade is associated with high costs, as discussed in Hahn et al. [7]. Alternative flexibilisation concepts provide the adjustment of the feeding management in order to be able to produce biogas in a demand-oriented way [8]. This also enables longer-term (several days and seasonal) adjustments in electricity production.

Due to different reaction times for the conversion of used substrates into biogas, a coordinated feeding management is necessary. Mauky et al. [8,9] stated that substrates such as sugar beets and ground wheat grain have the greatest gas production potential within half a day due to fast degradation kinetics. Grass and maize silage typically reach only about half of the gas production potential within half a day. Slowly degradable substrates such as solid manure even need several days for the conversion to biogas. Furthermore, Mauky et al. [9] describes that after a longer feeding stop of 72 h the reaction times of the substrates used are slower after first feeding.

Therefore, it is necessary to align the operation of the biogas

* Corresponding author.

E-mail addresses: celina.dittmer@uni-hohenheim.de (C. Dittmer), j.krumpel@uni-hohenheim.de (J. Krümpel), Andreas.lemmer@uni-hohenheim.de (A. Lemmer).

plant for demand-driven energy production to a prospective timetable. This allows an adjusted feeding management considering different gas production kinetics and the intelligent use of available gas storage capacities. For this purpose, a forecast of power demand can be of great benefit.

Mathematical models for forecasting the power demand of a region have been described in the literature in recent years. The Auto-Regressive Integrated Moving Average (ARIMA) model is widely used in this context. The ARIMA-Model is based on the assumption, that the system is a function of its own behavior. Therefore, the correlation of past values is essentially used to forecast future values. ARIMA models are considered to be very robust and simple [10]. However, they are more suitable for short forecast horizons, with less predicted values. Therefore, data is often aggregated in less detailed time periods such as annual, monthly or weekly intervals [11,12]. The model errors become significantly higher for longer forecast horizons of many predicted values, so satisfactory results are often no longer achieved [13].

An alternative model, developed and described by De Livera et al. [14], is the Trigonometric seasonality Box-Cox transformation ARMA errors Trend and Seasonal (TBATS). In Brożyna et al. [15] it is already described in greater detail that traditional methods, such as the ARIMA model or exponential smoothing, are hardly suitable for longer-term forecasts with several seasonalities. Hence, the main feature of the TBATS model is to deal with multiple seasonalities by modelling each seasonality with a trigonometric representation based on Fourier terms. Therefore, the model can handle even higher frequency time series [16].

The aim of this research study is to evaluate a suitable forecast model that allows the generation of a prospective timetable for demand-oriented energy production by biogas plants. Taking into account the differentiated gas production kinetics, a forecast of the power demand in hourly resolution over at least 48 h in advance should be achieved. The general quality as well as strengths and weaknesses of the selected forecast models are examined based on various evaluation parameters. In a further step, the quality of the forecast models is also set in relation to the forecast horizon in order to show whether a sufficiently accurate forecast of the power demand is also possible over longer periods.

2. Materials and methods

2.1. Development of forecast model

The forecasting method was limited to the area of time series analysis. All programming for visualisation, modelling and forecasting was done by using the programming language R [17]. Specific packages are referenced in the following wherever appropriate. All data used is collected, consolidated and made available via a “relational database”. Data was acquired by a “real-world laboratory” to ensure the practical relevance.

2.1.1. Databasis

The forecast model is intended to predict the power demand for a typical rural region in which biogas plants are primarily operated. The location “Unterer Lindenhof” in Eningen unter Achalm, southwest Germany, which is the site of the experimental station for agricultural science at the University of Hohenheim, was used. The location has an agricultural area of nearly 180 ha. In addition, a medium-sized livestock of pigs is kept, as well as cattle, sheep and poultry. A total of 42 employees as well as several apprentices and trainees are engaged in managing this agricultural site. Therefore, the location also has office space, a staff canteen and individual residential units. With an annual power consumption of approx. 750,000 kWh, the energy requirement of the “Unterer Lindenhof”

corresponds roughly to a smaller village with 150 inhabitants.

Since March 2016, the historical data of the power consumption have been made available via the local measuring point operator and was aggregated to hourly values. Thus, the resulting time series is presented in the resolution in which the forecast is to be mapped.

To get a detailed insight into the structure of the time series, it is broken up into its components. By decomposing with Loess (Local regression) the components season, trend and remainder were described separately [18]. A decisive advantage is offered by the fact that no rigid seasonal figures are shown, rather, these can change over time. To extract the multiple seasons, i.e. day/night cycles as well as weekday/weekend, a multiple season decomposition by means of the *mstl* function of the *forecast* package by Hyndman et al. [19] was used. Additionally, the augmented dickey fuller test was applied to determine whether the time series is stationary [20].

This insight into the time series allowed the selection of necessary models defined in the following section.

2.1.2. Selection of models

To ensure accurate modelling and achieve a precise forecast horizon, the number of observations is essential.

As discussed in Hyndman & Kostenko [21] no fundamental statement could be made about the necessary number of observations. The more complex the time series, the more observations are needed to define suitable model parameters for describing the complexity. For the present time series, it was particularly important to consider all seasonal patterns. For this reason, the time series was limited to 720 observations, which corresponds to a period of one month, covering both daily and weekly seasonal patterns.

To model the time series, two main approaches were considered: 1) Auto-Regressive Integrated Moving Average (ARIMA) and 2) Trigonometric seasonality Box-Cox transformation ARMA errors Trend and Seasonal (TBATS). A seasonal naive model was used as a benchmark.

2.1.2.1. ARIMA. The ARIMA model is classified by three orders, according to ARIMA (p, d, q). The order of autoregression p and the moving average q can be derived from autocorrelation and partial autocorrelation plots. The order d indicates the degree of differentiation necessary to make the time series stationary.

If seasonality is present, modelling of the non-seasonal part of the time series is complemented by including additional seasonal orders via ARIMA (p d q)(P D Q)_m. The orders P, D and Q are derived for the seasonal part exactly as described for the orders of the non-seasonal part p, d and q, whereby m is the frequency [18].

For the present approach, automatic operation is achieved by using the *auto.arima* function of the *forecast* package [19]. As described in Hyndman & Khandaskar [22] the number of ordinary differences for d and, if applicable, the number of seasonal differences for D are determined via unit root tests. Subsequently the selection of the other model parameters p, q, P and Q are determined by choosing the model with the lowest Akaike Information Criterion (AIC), which is further described in Ref. [23]. The defined frequency of the time series is m.

Two additional methods were applied while the standard ARIMA model was supplemented by further functions. By using objects from the decomposed time series via the *stlm* function of the *forecast* package [19], the seasonally adjusted time series is modelled by a non-seasonal ARIMA-model and afterwards re-seasonalised.

Another possibility for the explicit consideration of seasonality is the use of Fourier terms. With a series of sine and cosine terms, a periodic function respectively seasonal pattern can be approximated. For this purpose, the function *fourier* of the *forecast* package [19] was used as an external regressor and combined with the

auto.arima function. The number of Fourier terms (k_1 , k_2) per season was set to $k_1 = 6$ for daily season and $k_2 = 8$ for weekly season.

2.1.2.2. TBATS. De Livera, Hyndman & Snyder developed an alternative approach for time series with several seasonalities. As described in Ref. [14] the TBATS model contains a combination of Fourier terms with exponential smoothing and a Box-Cox transformation in a completely automated manner. The automatic operation is achieved by using the function *tbats* via the R-Package *forecast* [19].

The model is constructed as follows

$$\text{TBATS}(\Omega, \{p, q\}, \phi, \{<m_1, k_1>, <m_2, k_2>, <\dots, \dots>, <m_t, k_t>\}) \quad (1)$$

whereby the parameters are defined as.

- Ω Box-Cox-Parameter, described in Ref. [14].
- p, q ARMA-orders p and q
- ϕ damping parameter, described in Ref. [18].
- m_t, k_t seasonal figures, orders of Fourier terms

The Box-Cox parameter is used to achieve homoscedasticity in the time series. The error is modelled as an ARMA(p, q) process. With the damping parameter, a trend can be eliminated if needed and the seasonal figures are defined over the time periods with the necessary number of Fourier terms.

2.1.2.3. Seasonal naïve. The seasonal naïve model is used as a benchmark. The function *snaive* from the R package *forecast* is chosen. This simple model corresponds to an ARIMA (0, 0, 0)(0, 1, 0)_[m=168], whereby each forecast value is taken from the historical value one frequency ago, as defined by m [18].

2.1.2.4. Forecasting. The automatic forecasting is done by using the function *forecast* via the R-Package *forecast* [19]. This generic function refers to the parameters of the selected model and the specific forecast horizon. To evaluate the models, a forecast horizon of 48 h is chosen. For a total period of one year, forecasts are made every 24 h of the coming 48 h. For each new forecast, the model parameters are automatically redetermined on the basis of the historical data for the last 720 h.

In a further step, the forecast horizon is extended to 336 h. This enabled an investigation of how the forecast quality changes the further into the future the forecast is made.

2.2. Quality of forecast model

The assessment of forecast quality was carried out by using different accuracy-parameters. The widely used *Mean Absolute Percentage Error* (MAPE) and *Root Mean Squared Error* (RMSE) serve as general parameters for calculating the forecast quality and can be used for comparison with results in the literature. They are defined as follows:

$$\text{MAPE} = \frac{1}{E} \sum_{t=1}^E \left| \frac{z_t - z_t^f}{z_t} \right| \cdot 100 \% \quad (2)$$

$$\text{RMSE} = \sqrt{\frac{1}{E} \sum_{t=1}^E (z_t - z_t^f)^2} \quad (3)$$

In functions (2) and (3), E denotes the number of observations. z_t^f is the forecast value and z_t corresponds to the observed value.

In addition, the maximum positive and negative deviations between forecast values and observed values are used as parameters for evaluating the models.

These maximum deviations are explicitly relevant for the operation of a biogas plant. If much more power demand is forecasted than actually occurs (positive error), excess biogas is produced. Conversely, if occurring power demand is larger than the forecasted value, the biogas production is insufficient to cover the demands (negative error).

3. Results and discussion

3.1. Characteristics of the time series

To illustrate the database the power demand of the location “Unter Linden” was selected in hourly resolution over the entire year 2019. Fig. 1 shows the course of the time series.

The time series does not include any major outliers, with one exception during the month of September. Several seasonalities are visible, but without dependence on the annual seasons such as summer and winter. The mean value of the time series is 92.02 kW. The calculated standard deviation is 22.09 kW, resulting in values fluctuating more than 25% around the mean value. This is confirmed by the large range of 172.5 kW between the smallest value of 52.5 kW and the largest value of 225 kW, excluding the outlier in September.

The results of the time series decomposition are shown in Fig. 2. For better illustration, only the first three weeks of June are presented. It demonstrates the presence of two distinctive seasonal patterns leaving a smooth trend and a white noise remainder. In Fig. 2(a), grey vertical lines identify the Monday, i.e. the beginning of the week. By analysing these observed values in a range between 66 and 179 kW, it becomes apparent that the time series contains recurring patterns. Their identification is essential for a forecast, as it offers an indication of the potential future course of the time series.

Accordingly, Fig. 2(b) and (c) show the extracted existing seasonal figures. The daily season is clearly comprehensible in that the power demand is regularly higher during the day than during the night. By day, in the midday hours, the seasonal figure reaches a peak of maximum 37 kW. During the afternoon and evening the curve drops, until a minimum of −20 kW is reached at night. Moreover, it becomes clear that this seasonal figure hardly changes significantly over time. Only in the third week, the daily peak in power demand is slightly more pronounced.

Fig. 2(c) illustrates that there is a reduced power demand at weekends compared to weekdays. Minimum values, which indicate low consumption on weekends, drop to −35 kW. In the middle of the week, the seasonal figure reaches maximum values of up to 43 kW. This seasonal figure has no changes over the three weeks. On the one hand, this is explained by a relatively rigid seasonal pattern and on the other hand, by the fact that only a time window of three weeks is represented.

The component trend of the time series is shown in Fig. 2(d). There is no linear, logarithmic or exponential development. Furthermore, the range of 14 kW, in which the trend proceeds, is very small. Therefore, it can be concluded that the time series does not have a pronounced trend in this period.

The component remainder, shown in the bottom panel (Fig. 2(e)), describes the remaining part of the time series after subtraction trend and seasonal patterns. Ideally, the remainder is random white noise with no correlating values. A small remainder means that a more precise modelling can be achieved, as there are




Fig. 1. Power demand of the location “Unterer Lindenhof” in 2019 in hourly resolution.




Fig. 2. Decomposed time series of the power demand of the location “Unterer Lindenhof” over a period from June 1 to June 21, 2019: (a) Observed values, in which the Mondays are highlighted by a grey vertical line; (b) daily season; (c) weekly season (d) trend; (e) remainder.

less random fluctuations.

Thus, the time series at hand follows a recurring pattern with multiple seasonalities, expressed in daily, weekly and yearly figures. Consequently, a model that can handle multiple time series is required.

3.2. Test forecast models and evaluation

Due to the automatic, recurring modelling, using four weeks of historical data to forecast the upcoming 48 h, the models not only handle the implemented daily and weekly seasons but also, as a




Fig. 3. Several individual forecasts using TBATS with a 48h-horizon of power demand at the location “Unterer Lindenhof” in hourly resolution with a time window from January to July 2019.

whole, consider the yearly seasonality. As an example, Fig. 3 depicts one of the five tested forecast models with 91 individual forecasts overlaid with measured data.

Each individual forecast predicts 48 h of power demand amounting to a combined six month, as visualised.

For a detailed evaluation of all selected models a total of 365 forecasts from each of the models were assessed by different quality parameters. For this purpose, the four selected models plus the benchmark performed a forecast over 48 h every 24 h of the year 2019. This is equivalent to 17,520 forecasted values by each model. The results are summarised in Table 1.

A comparison of the results of the tested forecast models does not show any major differences, excluding the *aut_arima* model, which has underperforming results compared to the benchmark. The three other models are in a similar range. With a MAPE between 13 and 14%, the forecast models are within reasonable limits, compared to references from the literature. Values for MAPE as high as 80% were reported by Hirsch et al. [24], using a seasonal ARIMA model for forecasting power demand of individual households. This is attributable to the fact that irregularities in power consumption of one person have more impact than of a large number of consumers. On the other hand, MAPE values of 3% may be accomplished when evaluating power demand forecasts of a whole country (Turkey), as reported by Yukseltan et al. [25].

For all tested forecast models, negative errors occur significantly more often than positive errors. This is plausible, since unexpected events rather lead to an increased power demand than to a sudden drop in power consumption.

In general, the model *fou_arima* is best suited for the present

time series. Fewer errors in the modelling became visible, the multiple seasonalities were well considered and it consistently achieved the best results. Nevertheless, especially for complex, high frequency time series it could be difficult to develop good and functional specific models. Furthermore, these models are not directly adaptable to any different time series.

The *tbats* model offers a simple and automated variant. In comparison to the *aut_arima* model, it can handle multiple time series and therefore delivers similarly good results as the individually developed models.

3.3. Test different forecast horizons

The results of the evaluated models are based on a forecast horizon of 48 h, which is the minimum necessary to allow an adjusted feeding management for biogas plants.

In a further evaluation, it was tested whether the models can also achieve sufficiently precise results over a longer forecast horizon. Based on the MAPE of all models, Fig. 4 shows how the quality of the forecasts changed over time.

With all models, forecasts were performed with a forecast horizon of 336 h 24-hour segments of the total forecasts were analysed to identify the degree to which the quality of the forecasts degrades the further in advance the data is predicted.

It was confirmed that the model *aut_arima* is the least suitable. This was shown by a clearly higher MAPE with increasing forecast horizon compared to the other models. With a forecast horizon of 24 h, the models performed as expected. The *fou_arima* and the *tbats* provided the best forecast quality with an average MAPE of

Table 1
Quality parameter of the selected forecasting models.

Model	Number of forecasted values	MAPE [%]	RMSE [kW]	Max. positive error (abs.) [kW]	Max. positive error (rel.) [%]	Number positive error (abs.) > 50 kW	Max. negative error (abs.) [kW]	Max. negative error (rel.) [%]	Number negative error (abs.) > 50 kW
Benchmark (sea_naive)	17'520	15.46	19.00	103.30	217.05	220	110.80	234.63	300
ARIMA + decomposition (stl_arima)	17'520	13.75	16.71	69.36	177.36	69	98.10	228.00	221
ARIMA + Fourier terms (fou_arima)	17'520	13.34	15.69	61.20	318.57	9	87.35	218.12	197
ARIMA automated (aut_arima)	17'520	15.76	19.10	110.27	214.26	199	106.27	286.34	300
TBATS automated (tbats)	17'520	14.07	16.97	61.49	232.59	21	101.91	271.55	316




Fig. 4. Comparison of the quality parameter MAPE of all tested models and the benchmark for different forecast horizons. The sections of the considered forecast horizon are listed in hours.

12.36% and 12.92%. The *stl_arima* also reached 12.98%. The *aut_arima* provides even better results with 14.65% than the benchmark *sea_naive* with 15.41%. As the forecasting horizon expands, it became apparent that the models *fou_arima* and *tbats* consistently achieved the best results. For the purpose at hand, it is demonstrated that these models are capable of producing high-quality forecasts even over long forecast horizons of 14 days. The MAPE, calculated from the results of the section 313 to 336 hours, for the model *fou_arima* is 15.16%. The *tbats* model still achieved a MAPE of 17.08%.

The present investigations prove that the forecast models achieve accurate results to orientate the operation of a biogas plant to the forecasted power demand, even over the long period of 14 days in advance. In fact, this allows an adjusted feeding management with regard to the use of substrates with low gas production kinetics.

4. Conclusion

Future operation of a biogas plant should be orientated on a fluctuating power demand; therefore, forecasts will be of great benefit. In this study, four forecast models for power demand were evaluated using data from the “real-world laboratory” “Unterer Lindenhof”. The most important criterion is that the model has to consider multiple seasonalities.

All selected models achieve a MAPE between 13 and 16% over a forecast horizon of 48 h. Hence, it can be concluded that in principle all models are suitable for the purpose at hand. The model *fou_arima* shows slightly better results than the other models, and is therefore favoured for the present time series. The *TBATS* model has the advantage that all model parameters are calculated automatically and could therefore be better adapted to other time series.

Furthermore, it was shown that the forecast models are also suitable for longer forecast horizons. In this purpose, the results of a forecasted power demand over 336 h show a consistently low MAPE between approximately 15–17%. With these possible long-term forecasts, even longer planning timetables for feeding

management and thus a better adjustment of the biogas plant operation to the power demand are allowed.

CRediT authorship contribution statement

Celina Dittmer: Conceptualization, Methodology, Software, Validation, Formal analysis, Investigation. **Johannes Krümpel:** Project administration, Writing – review & editing, Software, Data curation. **Andreas Lemmer:** Supervision, Project administration, Funding acquisition, Writing – review & editing, Resources.

Declaration of competing interest

The authors declare that they have no known competing financial interests or personal relationships that could have appeared to influence the work reported in this paper.

References

- [1] J. Grim, D. Nilsson, P.-A. Hansson, Å. Nordberg, Demand-orientated power production from biogas: modeling and simulations under Swedish conditions, *Energy Fuels* 29 (2015) 4066–4075, <https://doi.org/10.1021/ef502778u>.
- [2] Regulation (Eu), OF the EUROPEAN parliament and OF the council of 11 december 2018 on the governance of the energy union and climate action, 2018/1999, Off. J. the Eur. Union L328 (2018).
- [3] Ch. Kost, S. Shammugam, V. Jülich, H.-T. Nguyen, T. Schlegel, *Stromgestehungskosten Erneuerbare Energien*, 2018.
- [4] E. Kumanowska, S. Zielonka, J. Krümpel, P. Kress, H. Oechsner, Novel system for demand-oriented biogas production from sugar beet silage effluent in German practice scale biogas plants, *Agrartechnik* 22 (2020) 1.
- [5] R. Pereira, J. Figueiredo, R. Melicio, V.M.F. Mendes, J. Martins, J.C. Quadrado, Consumer energy management system with integration of smart meters, *Energy Rep.* 1 (2015) 22–29, <https://doi.org/10.1016/j.egy.2014.10.001>.
- [6] T. Barchmann, E. Mauky, M. Dotzauer, M. Stur, S. Weinrich, H.F. Jacobi, J. Liebetrau, M. Nelles, Expanding the flexibility of biogas plants – substrate management, schedule synthesis and economic assessment, *Landtechnik* 71 (2016) 6, <https://doi.org/10.1515/LT.2016.3146>.
- [7] H. Hahn, W. Ganagin, K. Hartmann, M. Wachendorf, Cost analysis of concepts for a demand oriented biogas supply for flexible power generation, *Bioresour. Technol.* 170 (2014) 211–220, <https://doi.org/10.1016/j.biortech.2014.07.085>.
- [8] E. Mauky, S. Weinrich, H.-J. Nägele, H.F. Jacobi, J. Liebetrau, M. Nelles, Model predictive control for demand-driven biogas production in full scale, *Chem. Eng. Technol.* 39 (2016) 652–664, <https://doi.org/10.1002/ceat.201500412>.
- [9] E. Mauky, S. Weinrich, H.-F. Jacobi, H.-J. Nägele, J. Liebetrau, M. Nelles,

- Demand-driven biogas production by flexible feeding in full-scale – process stability and flexibility potentials, *Anaerobe* 46 (2017) 86–95, <https://doi.org/10.1016/j.anaerobe.2017.03.010>.
- [10] E. Caro, J. Juan, J. Cara, Periodically correlated models for short-term electricity load forecasting, *Appl. Math. Comput.* 364 (2020) 124642, <https://doi.org/10.1016/j.amc.2019.124642>.
- [11] S. Li, R. Li, Comparison of forecasting energy consumption in shandong, China using the ARIMA model, GM model, and ARIMA-GM model, *Sustainability* 9 (2017) 1181, <https://doi.org/10.3390/su9071181>.
- [12] S.G. Chavez, J.X. Bernat, H.L. Coalla, Forecasting of energy production and consumption in Asturias (northern Spain), *Energy* 24 (3) (1998).
- [13] A.E. Clements, A.S. Hurn, Z. Li, Forecasting day-ahead electricity load using a multiple equation time series approach, *Eur. J. Oper. Res.* 251 (2) (2016).
- [14] A.M. De Livera, R. Hyndman, R. Snyder, *Forecasting Time Series with Complex Patterns Using Exponential Smoothing*, 2010.
- [15] J. Brożyna, G. Mentel, B. Szetela, Influence of double seasonality on economic forecasts on the example of energy demand, *J. Int. Stud.* 9 (2016) 9–20, <https://doi.org/10.14254/2071-8330.2016/9-3/1>.
- [16] O.A. Karabiber, G. Xydīs, Electricity price forecasting in the Danish day-ahead market using the TBATS, ANN ARIMA Methods *Energies* 12 (5) (2019).
- [17] R.G.R. Ihaka, R: a language for data analysis and graphics, *J. Comput. Graph Stat.* 5 (3) (1996).
- [18] R. Hyndman, G. Athanasopoulos, *Forecasting: Principles and Practice*, second ed., OTexts, Melbourne, Australia, 2018.
- [19] R. Hyndman, G. Athanasopoulos, Ch Bergmeir, G. Caceres, L. Chhay, M. O'Hara-Wild, F. Petropoulos, S. Razbash, E. Wang, F. Yasmeeen, R. Team, R. Ihaka, D. Reid, D. Staub, Y. Tang, Z. Zhou, *Forecasting Functions for Time Series and Linear Models*, 2020, Version 8.11.
- [20] D.A. Dickey, W.A. Fuller, Distribution of the estimators for autoregressive time series with a unit root, *J. Am. Stat. Assoc.* 74 (1979) 366.
- [21] R. Hyndman, A.V. Kostenko, Minimum Sample Size Requirements for Seasonal Forecasting Models, *Foresight*, 2007.
- [22] R.J. Hyndman, Y. Khandakar, Automatic time series forecasting: the forecast package for R, *J. Stat. Software* 27 (3) (2008).
- [23] H. Akaike, *Information Theory and an Extension of the Maximum Likelihood Principle*, 1973.
- [24] Ch Hirsch, *Fahrplanbasiertes Energiemanagement in Smart Grids*, Dissertation, 2015.
- [25] E. Yukseltan, A. Yucekaya, A.H. Bilge, Forecasting electricity demand for Turkey: modeling periodic variations and demand segregation, *Appl. Energy* 193 (2017) 287–296, <https://doi.org/10.1016/j.apenergy.2017.02.054>.

3. Publikation 2: Modeling and Simulation of Biogas Production in Full Scale with Time Series Analysis

Celina Dittmer^a, Johannes Krümpel^a, Andreas Lemmer^a

^a *Landesanstalt für Agrartechnik und Bioenergie, Universität Hohenheim, Garbenstrasse 9, 70599 Stuttgart, Germany*

Informationen Publikation:

Publiziert: Microorganisms 2021, 9(2), 324

Empfangen: 16. Dezember 2021

Akzeptiert: 1. Februar

DOI: 10.3390/microorganisms9020324

Online: seit 5. Februar 2021 unter <https://doi.org/10.3390/microorganisms9020324>

Abstract

Future biogas plants must be able to produce biogas according to demand, which requires proactive feeding management. Therefore, the simulation of biogas production depending on the substrate supply is assumed. Most simulation models are based on the complex Anaerobic Digestion Model No. 1 (ADM1). The ADM1 includes a large number of parameters for all biochemical and physicochemical process steps, which have to be carefully adjusted to represent the conditions of a respective full-scale biogas plant. Due to a deficiency of reliable measurement technology and process monitoring, nearly none of these parameters are available for full-scale plants. The present research investigation shows a simulation model, which is based on the principle of time series analysis and uses only historical data of biogas formation and solid substrate supply, without differentiation of individual substrates. The results of an extensive evaluation of the model over 366 simulations with 48-h horizon show a mean absolute percentage error (MAPE) of 14–18%. The evaluation is based on two different digesters and demonstrated that the model is self-learning and automatically adaptable to the respective application, independent of the substrate's composition.

Key words: demand-orientated; ADM1; self-learning; regression model; forecast; prediction



Article

Modeling and Simulation of Biogas Production in Full Scale with Time Series Analysis

Celina Dittmer *, Johannes Krümpel and Andreas Lemmer

State Institute of Agricultural Engineering and Bioenergy, University of Hohenheim, Garbenstrasse 9, 70599 Stuttgart, Germany; j.kruempel@uni-hohenheim.de (J.K.); andreas.lemmer@uni-hohenheim.de (A.L.)

* Correspondence: celina.dittmer@uni-hohenheim.de; Tel.: +49-711-459-24781

Abstract: Future biogas plants must be able to produce biogas according to demand, which requires proactive feeding management. Therefore, the simulation of biogas production depending on the substrate supply is assumed. Most simulation models are based on the complex Anaerobic Digestion Model No. 1 (ADM1). The ADM1 includes a large number of parameters for all biochemical and physicochemical process steps, which have to be carefully adjusted to represent the conditions of a respective full-scale biogas plant. Due to a deficiency of reliable measurement technology and process monitoring, nearly none of these parameters are available for full-scale plants. The present research investigation shows a simulation model, which is based on the principle of time series analysis and uses only historical data of biogas formation and solid substrate supply, without differentiation of individual substrates. The results of an extensive evaluation of the model over 366 simulations with 48-h horizon show a mean absolute percentage error (MAPE) of 14–18%. The evaluation is based on two different digesters and demonstrated that the model is self-learning and automatically adaptable to the respective application, independent of the substrate's composition.



Citation: Dittmer, C.; Krümpel, J.; Lemmer, A. Modeling and Simulation of Biogas Production in Full Scale with Time Series Analysis. *Microorganisms* **2021**, *9*, 324. <https://doi.org/10.3390/microorganisms9020324>

Academic Editor: Florian Centler, Sören Weinrich and Denny Popp
Received: 16 December 2020
Accepted: 1 February 2021
Published: 5 February 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Keywords: demand-orientated; ADM1; self-learning; regression model; forecast; prediction

1. Introduction

Worldwide, it is imperative that the energy supply based on renewable energy resources increases. In Germany, the Renewable Energy Act stipulates that 80% of the gross electricity supply must be covered by renewable energies by the year 2050 [1]. Due to low production costs and greenhouse emissions, the future power systems will be characterized by fluctuating feeds from wind turbines and photovoltaics (PV). Therefore, technologies to balance the divergence between energy supply and demand are gaining increasing relevance. Besides the adapted behavior of energy consumers (demand-side management) and the installation of new electricity storage capacities, a higher importance will be placed on load-flexible and modular energy production [2]. In this context, bioenergy, especially biogas plants, can play a crucial role. Compared to biogas plants designed for constant load, the demand-oriented, load-flexible use of biogas requires significantly larger combined heat and power units (CHP) and corresponding gas storage facilities [3]. However, on-site gas storages are limited for cost, safety, and licensing reasons [4]. Future biogas plants must therefore also be able to produce biogas according to demand, which in turn requires proactive feed management [5]. Such intelligent feeding systems can also reduce the construction costs of biogas plants, as the required gas storage capacities can be reduced by up to 65% [6].

Concepts for feeding management require the simulation of biogas production depending on the substrate supply [7]. Most simulation models are based on the complex Anaerobic Digestion Model No. 1 (ADM1), edited by [8]. Parameters of all biochemical process steps (hydrolysis, acidogenesis, acetogenesis, methanogenesis) as well as physicochemical processes (ion association/dissociation and gas-liquid transfer, etc.) are considered in this model [9]. According to Gaida et al. [10], the main challenges are a deficiency

of reliable measurement technology and process monitoring in full-scale plants to provide the required data for the model parameters. Therefore, Weinrich et al. [5–7] developed approaches to reduce the complexity of the ADM1, for example by representing the fermentation of carbohydrates, fats, and proteins by simply three reactions. This model works in summary on a simplified stoichiometry of the model presented by Angelidaki [11,12] and uses first-order kinetics to simulate the total biogas production of the fermentation process [7]. A further example of a simplified model is the AMOCO model, described in [13], which only considered the acidogenic and methanogenic bacterial populations. Since this can only be used to model the degradation of soluble materials, a first-order hydrolysis step could be included in order for it to be applicable to the degradation of particulate materials [14].

Nevertheless, the simplified models still presuppose a number of input parameters, which primarily include the composition and degradation behavior, respectively, of the gas formation kinetics of the used substrates. Since nearly none of these parameters are available for full-scale plants, they are approximated by referring to data from experiments under laboratory conditions and digestive experiments on ruminants [7].

In full-scale biogas plants, the kinetics of gas formation are mainly influenced by the following parameters: the substrates used [15,16], the process temperature [17], the retention time [18], the availability of the micronutrients essential for methanogenic microorganisms [19], the ammonium nitrogen concentration in the fermentation substrate [20], and other parameters such as, for example, those described in [21]. To represent the conditions of the respective full-scale plant, all model parameters have to be carefully adjusted to the actual process state [22].

An additional approach to modeling anaerobic digestion processes is represented by data-driven models, which use, for example, artificial neural networks. An evaluation of these modeling techniques is presented in [23]. The present research investigation aims at a fundamentally different data-driven model for the simulation of biogas production in a full-scale plant, which is based on the principle of time series analysis. Using this model, correlations between time series of substrates addition and gas formation are analyzed and mathematically described. As this new model is based on time series analysis, it is self-learning and automatically adapts to the respective application, independent of the digester size and the substrates fed in.

2. Materials and Methods

2.1. Databasis, Experimental Setup

All data used are from a full-scale biogas plant, more precisely the research biogas plant of the experimental station for agricultural science at the University of Hohenheim. The plant is operated at the location “Unterer Lindenhof” in Eningen unter Achalm, southwest Germany. The plant setup consists of two continuous stirred-tank reactors (digesters), which are covered with insulated concrete, and a secondary digester, fitted with a double membrane gas storage. Each of the three tanks has a volume of 923 m³. Digesters operate in the mesophilic range at 43 ± 4 °C. On average, 130 m³ h^{−1} biogas is produced (year 2018), with approximately 51 vol % methane (CH₄) and 49 vol % carbon dioxide (CO₂). The measurement of biogas production is done by a flow meter with an oscillating measuring method (hot wire sensor, company Esters Elektronik GmbH, type GD300), and is implemented separately for each digester in the biogas pipe directly at the digester outflow. The biogas is utilized via CHP-unit with an installed power of 355 kW_{el}.

The supply of solid substrates is achieved via vertical mixer feeding systems, whereby both digesters have a separate feeding system. Liquid substrates are added by pumps. The quantity of substrates used is recorded by the weighing cells of the feeding system or measured via a flow meter. The hydraulic retention time (HRT) amounts to ~120 days in total. A much more detailed description of the setup of this research biogas plant can be found in Naegele and Lemmer et al. [24,25].

The data used, at an hourly resolution, the measured quantities of solid substrate (via feeding system) given in kg h^{-1} and the produced biogas quantities under standard conditions in $\text{m}^3 \text{h}^{-1}$. In a further investigation, the measured quantities of liquid substrates in kg h^{-1} from both digesters were taken into account. The evaluation of the model was performed using two differentiated data sets by considering both digesters as independent systems.

All measured data are recorded and logged by the central control system of the biogas plant, and are afterwards collected, consolidated, and made available via a relational database. As a basis for the research, data from the year 2018 were used. As there were no research experiments with different feeding concepts this year, the data can be considered representative for a typical biogas plant operation.

2.2. Development of Process Model

All programming for visualization, modelling, and simulating was done by using the programming language R [26]. Wherever appropriate, specific packages are referenced in the following.

2.2.1. Time Series Analysis

The correlations between the time series of substrate supply as the independent variable and biogas production as the dependent variable has been monitored by using the cross-correlation function. Thus, it was determined that one series related to past lags of the other series and could be used as a predictor. This analysis was done by means of the *ccf()* function of the *stats* package by P. Gilbert et al. [27].

2.2.2. Regression Model

The basis of the developed regression model is the linear regression, expressed by the following Equation (1)

$$Y_i = \alpha + \beta X_i + \varepsilon_i \quad (1)$$

whereby Y_i is the dependent and X_i the independent variable. The intercept is expressed as α , β is the slope of the line, and ε_i is the error term. By including liquid manure as a second independent variable, additional β_n were inserted, which are equivalently multiplied by the X_i -values. As examined by the cross-correlation function, the X -variables influence the Y -variables with time lag. Accordingly, the formula has to be adjusted with a defined number of past values of X as explanatory variables (2) [28].

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \dots + \beta_k X_{t-k} + \varepsilon_t \quad (2)$$

The index t declares the point in time and k stands for the lag order. To estimate the parameters for fitting the best regression, the ordinary least square method (OLS) was used.

For the present approach, the function *dynlm()* from the R package *dynlm* was used [29]. It employs operators to compute a lagged version of the time series in order to determine the regression model according to Equation (2).

2.2.3. Simulating and Evaluation

The simulation was performed using the regression model with input data of solid substrates feeding, for which the biogas production has to be simulated, and the corresponding lagged values.

With regard to a precise simulation of the future biogas production, the model settings had to be determined optimally. Therefore, the model was identified for (1) a suitable number of historical data (training period). Considering the model parameters with (2) a suitable number of lags, simulations can be performed over (3) a defined simulation horizon.

- (1) In order to consider the most current process conditions, the training period for the model should not be too long. This ensures a simulation period with approximately the same conditions as the period of prediction of the model parameters. Therefore, the numbers of 200, 500, and 800 h were evaluated.
- (2) For the identification of an appropriate number of lags, it is decisive to determine in which time period the significant changes in biogas production after feeding are apparent. As described in Mauky et al. [6], feeding grass and maize silage released 62% of the total biogas production in the first 12 h after feeding. For the substrates sugar beet and crop, it is even 72%. Accordingly, the model was evaluated with a small number of 48 lags, and additionally, 72 and 96 lags.
- (3) A horizon of 48 h was initially defined for the simulation. In further studies, this horizon was extended. This enabled an investigation of how the simulation quality changes the further into the future the simulation is made.

For all possible combinations of the model parameters training period, lags, and simulation horizon, the simulation model was running for every day of the year 2018 and the quality of the simulations was calculated. In total, 366 simulations were performed for each evaluation. In addition, this evaluation process was performed for the time series of digester one and digester two.

2.3. Quality of Simulation Model

The evaluation of simulation quality was carried out by using different accuracy parameters: the mean absolute percentage error (MAPE), the mean absolute error (MAE), and the root mean squared error (RMSE).

The MAPE is defined as follows (3):

$$MAPE = \frac{1}{E} \sum_{t=1}^E \left| \frac{z_t - z_t^s}{z_t} \right| \times 100\% \quad (3)$$

The MAE was additionally applied (4):

$$MAE = \frac{1}{E} \sum_{t=1}^E |z_t - z_t^s| \quad (4)$$

The third selected accuracy parameter, the RMSE, is defined as follows (5):

$$RMSE = \sqrt{\frac{1}{E} \sum_{t=1}^E (z_t - z_t^s)^2} \quad (5)$$

In Equations (3)–(5), E denotes the number of observations, z_t^s is the simulated value, and z_t corresponds to the observed value.

For the present approach, the accuracy parameters are calculated using the R functions `mape()`, `mae()`, and `rmse()` from the R package *metrics* [30].

3. Results and Discussion

3.1. Results of Time Series Analysis

A first insight into solid substrate feeding and biogas production for digester one and digester two is presented in Figure 1, using data from 2018 in hourly resolution.

Digester one (Figure 1, top) was supplied with solid substrate that contained 21% solid dung, 39% maize silage, 34% grass silage, 2% whole crop silage, and 4% sugar beets. On average, 5995.34 ± 2097.37 kg of solid substrates were fed daily. Related to hourly resolution, a total of 13 feedings include a weight of more than 2000 kg h^{-1} . The resulting biogas production was $70.25 \pm 18.63 \text{ m}^3 \text{ h}^{-1}$ with a total range between $2.26 \text{ m}^3 \text{ h}^{-1}$ (except value 0) and $163.89 \text{ m}^3 \text{ h}^{-1}$.

Digester two (Figure 1, bottom) was similarly fed with solid substrate containing 22% solid dung, 37% maize silage, 39% grass silage, and 2% whole crop silage, but no sugar beet. Here, the daily solid substrate input was $6565.23 \pm 3397.46 \text{ kg d}^{-1}$. Furthermore, the feedings show more irregularities, because altogether 28 times feeding over 2000 kg h^{-1} was registered. The mean biogas production is comparable with a value of $61.66 \pm 29.71 \text{ m}^3 \text{ h}^{-1}$. The range of biogas production is also similar, with values between $1.02 \text{ m}^3 \text{ h}^{-1}$ (except value 0) and $160.20 \text{ m}^3 \text{ h}^{-1}$.




Figure 1. Solid substrate supply and biogas production from digester one (top) and digester two (bottom) in 2018 in hourly resolution.

The listed amounts of the various substrates show the average values for 2018. For each feeding, the composition fluctuated, depending on the availability of the substrates. For example, in regular operations, when more solid dung is available in the winter months, less maize and grass silage are used.

A significant negative correlation between solid substrate feed and biogas production was determined by cross-correlation, thus confirming the requirement to use the values of the solid substrate feed as a predictor of biogas production.

3.2. Regression Model and Simulating

Results of the evaluation regarding suitable settings for length of training dataset, number of lags for the model, as well as length of simulation horizon are summarized in Table 1. The evaluation was carried out over a total of 19,764 simulations by running the simulations every 24 h in 2018 and comparing them with real data.

The comparison suggests that the best results for simulating the biogas production of both digesters are achieved with a training period of 500 observations and 48 lags. These model settings indicate the best values for most accuracy parameters. For 366 simulations with a horizon of 48 h each, average MAPEs of 18.13% (digester one) and 13.87% (digester two) could be determined. Similarly, the values for RMSE and MAE are approximately $10 \text{ m}^3 \text{ h}^{-1}$. Compared to an average biogas production of $\sim 70 \text{ m}^3 \text{ h}^{-1}$ (digester one) and $\sim 60 \text{ m}^3 \text{ h}^{-1}$ (digester two) with standard deviations of $\sim 19 \text{ m}^3 \text{ h}^{-1}$ and even $\sim 30 \text{ m}^3 \text{ h}^{-1}$, the values for RMSE and MAE are implied to be within reasonable limits. It must be mentioned that the MAE for digester two is slightly lower when using 72 lags. In general,

only very small differences in the evaluation results can be recognized, which suggests that in some cases the consideration of more than 48 lags could be useful.

Table 1. Evaluation of model settings (H: horizon; T: training; L: lag) using the accuracy parameters MAPE [%], RMSE [$\text{m}^3 \text{h}^{-1}$], and MAE [$\text{m}^3 \text{h}^{-1}$] for the time series from digester one (D1) and digester two (D2). Each combination shows the mean value of 366 individual simulations.

	MAPE [%]	MAPE [%]	MAPE [%]	RMSE [$\text{m}^3 \text{h}^{-1}$]	RMSE [$\text{m}^3 \text{h}^{-1}$]	RMSE [$\text{m}^3 \text{h}^{-1}$]	MAE [$\text{m}^3 \text{h}^{-1}$]	MAE [$\text{m}^3 \text{h}^{-1}$]	MAE [$\text{m}^3 \text{h}^{-1}$]
	H: 48	H: 96	H: 144	H: 48	H: 96	H: 144	H: 48	H: 96	H: 144
T: 200	D1: 22.27	D1: 23.37	D1: 24.55	D1: 14.37	D1: 15.92	D1: 17.15	D1: 11.88	D1: 12.71	D1: 13.44
L: 48	D2: 14.05	D2: 14.78	D2: 15.23	D2: 10.50	D2: 11.36	D2: 11.87	D2: 8.98	D2: 9.53	D2: 9.85
T: 200	D1: 26.20	D1: 27.91	D1: 29.22	D1: 17.31	D1: 19.28	D1: 20.72	D1: 14.35	D1: 15.50	D1: 16.32
L: 72	D2: 15.44	D2: 16.55	D2: 16.96	D2: 11.59	D2: 12.69	D2: 13.22	D2: 9.9	D2: 10.60	D2: 10.94
T: 200	D1: 30.79	D1: 32.78	D1: 34.46	D1: 20.55	D1: 23.14	D1: 24.98	D1: 17.03	D1: 18.59	D1: 19.62
L: 96	D2: 17.09	D2: 18.43	D2: 18.68	D2: 12.79	D2: 14.02	D2: 14.49	D2: 10.80	D2: 11.59	D2: 11.91
T: 500	D1: 18.13	D1: 18.92	D1: 19.57	D1: 11.48	D1: 12.40	D1: 13.25	D1: 9.77	D1: 10.28	D1: 10.84
L: 48	D2: 13.87	D2: 14.35	D2: 14.71	D2: 10.07	D2: 10.67	D2: 11.13	D2: 8.85	D2: 9.22	D2: 9.52
T: 500	D1: 19.08	D1: 20.01	D1: 20.68	D1: 12.06	D1: 13.09	D1: 13.95	D1: 10.24	D1: 10.87	D1: 11.44
L: 72	D2: 13.88	D2: 14.37	D2: 14.64	D2: 10.09	D2: 10.71	D2: 11.13	D2: 8.81	D2: 9.19	D2: 9.46
T: 500	D1: 19.98	D1: 20.88	D1: 21.40	D1: 22.77	D1: 13.80	D1: 14.59	D1: 10.81	D1: 11.44	D1: 11.93
L: 96	D2: 14.04	D2: 14.48	D2: 14.74	D2: 10.38	D2: 11.02	D2: 11.46	D2: 9.03	D2: 9.42	D2: 9.70
T: 800	D1: 19.24	D1: 19.51	D1: 19.98	D1: 11.67	D1: 12.51	D1: 13.31	D1: 10.06	D1: 10.58	D1: 11.13
L: 48	D2: 14.77	D2: 15.05	D2: 15.26	D2: 10.77	D2: 11.46	D2: 12.02	D2: 9.64	D2: 10.06	D2: 10.46
T: 800	D1: 19.78	D1: 20.20	D1: 20.88	D1: 12.01	D1: 12.99	D1: 13.92	D1: 10.34	D1: 10.98	D1: 11.64
L: 72	D2: 14.72	D2: 15.08	D2: 15.19	D2: 10.64	D2: 11.39	D2: 11.91	D2: 9.47	D2: 9.94	D2: 10.30
T: 800	D1: 20.50	D1: 20.84	D1: 21.47	D1: 12.43	D1: 13.44	D1: 14.36	D1: 10.64	D1: 11.31	D1: 11.96
L: 96	D2: 14.77	D2: 15.12	D2: 15.26	D2: 10.77	D2: 11.55	D2: 12.09	D2: 9.57	D2: 10.06	D2: 10.44

Additionally, the simulation model is capable of producing simulations even over long horizons of 144 h, because the accuracy parameters show only a slight increase with a longer simulation horizon.

As an example, the following Figure 2 shows the simulation results using a training period of 500 observations and 48 lags for digester two.




Figure 2. A total of 183 individual simulations, using a training period of 500 observations and 48 lags with a 48 h horizon, of biogas production for digester two, in hourly resolution, with a time window from January to December 2018. The simulated values are shown in blue, while the measured data are overlaid in black for comparison.

As can be recognized in Figure 2, the simulation model is able to forecast large fluctuations in biogas production, such as those seen at the end of May 2018, with a change between $75 \text{ m}^3 \text{h}^{-1}$ within one day. Otherwise, as seen in November, this abrupt increase in biogas production is only reflected by the model with a slight delay. In this respect, small deviations between simulation and real values may occur. Positively noticeable is the fact that zero values of the biogas production around the month of October are represented truthfully.

In well-known models such as the ADM1, changes in biogas production are predicted by processing various parameters and process steps of digestion. However, the applied model is able to self-learn by evaluating the relationship between the time series of the substrate supply and biogas production. Due to the recurring analysis of the most recent process data, gradual shifts in feed composition are automatically considered and can be accurately represented.

As the model always takes the individual data of a biogas plant, with the historic biogas production and feeding taken into account, the methodology is highly adaptive to a wide range of full-scale plants with their very own characteristics in terms of substrate feeding and conversion efficiency. For the presented approach, only minor or no adaptations of the methodology need to be taken into account to simulate the biogas production of other full-scale plants.

Nevertheless, further investigations and experiments regarding process failures and strong changes in feed composition would be useful to fully evaluate the extent of the reactivity of the approach. In summary, the developed model shows itself to be a very useful tool to simulate biogas production. Compared to existing simulation models, based on ADM1, only a minimum of input parameters are necessary, which can be supplied by conventional and generally implemented measurement technology. In addition to the availability of the data, it is guaranteed that data originates exclusively from the respective plant operation, and no additional assumptions based on laboratory tests are necessary. The requirements for future research projects in this area, defined by Gaida et al. [10], which include robust models in successful use in full-scale plants that are not dependent on extensive online measurement equipment and the ability to handle feeding of differentiated substrates, seems to be fulfilled with the present model.

The evaluation of the developed model also emphasized the reproducibility of the results and the adaptability to more systems by the large number of simulations (366 each), the high resolution (hourly), and the observation of two different examples of full-scale digesters (digester one and digester two).

Going deeper into details of the model parameters allows further results of the present research investigation. Figure 3 shows the boxplots of model coefficients from 366 simulations with training periods of 500 observations and 48 lags. The based time series include data from digester two.




Figure 3. Boxplots of model coefficients β from the simulations of digester two with 500 training-observations and 48 lags.

Figure 3 illustrates the calculated coefficients as an indication of the time-dependent development of biogas production in relation to the solid substrate supply. For the purpose at hand, it could be concluded that the impact on biogas production is greatest during the first 20 h after feeding solid substrates. This emphasizes the fact that considering a larger number of lags does not improve the results of the present model.

Further, the mapping of the median of the coefficients, visualised in Figure 3 by the red line, could indicate the course of the gas formation rate of the feeding substrates. By calculating the area under the curve, an average biogas production of $0.101 \text{ m}^3 \text{ kg}^{-1}$ within 48 h was determined. In alignment with the substrates composition used and related average biogas yields, listed in Amon et al. [15], the calculated biogas production seems rather low. It could be assumed that one reason is the fact that only 48 h are considered and consequently less than the total gas formation potential is represented. Furthermore, it can be postulated that a residual amount of biogas is included in the model parameter intercept. Nevertheless, this evaluation could be a promising way to assess the gas formation kinetics of substrates used in full-scale plants.

A further investigation of this circumstance demonstrates the consideration of an additional regressor as a predictor on the simulation results. Besides feeding solid substrates, the dosage of liquid substrates (liquid manure) was also considered. Despite this specification of the fed substrates, the results indicated a poorer quality of the simulation. The evaluation of 366 simulations with training periods of 500 observations and 48 lags for both the solid and liquid substrates resulted in a higher MAPE of 14.92% for digester two. For comparison, the MAPE for simulations without the additional consideration of liquid manure as a second regressor is 13.87%. (cf. Table 1). Figure 4 illustrates calculated coefficients of the regressor “liquid manure” from the model.




Figure 4. Boxplot with coefficients β of liquid substrate (liquid manure) feeding from simulation of digester two with 500 observations and 48 lags.

The coefficients fluctuate around zero along all lags. In most cases, the values even fall below zero. This is due to the fact that the calculation of the coefficients depends on the intercept. The intercept is basically not interpretable, unless there is no feeding, then it can be assumed that the intercept represents the mean biogas production. Negative coefficients, as partly shown in Figure 4, indicate a higher value of the intercept, for example due to extensive feedings in the past. In addition, the supply of liquid manure in this digester proceeds at almost constant intervals and equal amounts, which could be also

an explanation of the visualised coefficients. The resulting biogas production should be nearly unchanged; hence, it is not reflected in higher coefficients, but presumably included in the intercept.

The analysis of the coefficients allows for the conclusion that the feeding of liquid manure as an additional regressor has no added benefit for the simulation of biogas production in this case. It would be interesting to conduct further studies on full-scale liquid manure-based biogas plants or converting different dosages of liquid manure for the comparison of the results.

4. Conclusions

The results show a fundamentally different model for the simulation of biogas production in a full-scale plant. Using time series analysis, a simulation model could be developed, which would work exclusively with historical data of biogas production and data on the amount of fed solid substrates. This offers the advantage that all necessary data can be provided via standardized measuring technology of a full-scale biogas plant. The evaluation of the model on two digesters has shown the resistance and adaptability of the model to different operating conditions. This allows for its application with nearly all full-scale plants. The quality of the simulation results achieves a mean MAPE of well below 20% in an extensive analysis of 366 simulations. The MAE and RMSE are in good range, with mean values of about $10 \text{ m}^3 \text{ h}^{-1}$ at a mean production of about 70 and $60 \text{ m}^3 \text{ h}^{-1}$, respectively. Remarkably, simulation quality worsened when considering liquid manure as a second regressor in the model. Once again, the simplicity and practicability of the model is underlined, as it delivers very good results with a minimum of model parameters.

In an additional investigation, it could be shown that the simulation horizon extends beyond 48 h. The simulation model is capable of producing high-quality simulations up to at least 144 h.

Author Contributions: C.D.: conceptualization, methodology, software, validation, formal analysis, investigation; J.K.: project administration, writing—review & editing, software, data curation; A.L.: supervision, project administration, funding acquisition, writing—review & editing, resources. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the German Federal Ministry of Food and Agricultural, through the Fachagentur Nachwachsende Rohstoffe e.V., under the trademark 22404717.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Conflicts of Interest: The authors declare no conflict of interest.

References

1. Gesetz über den Ausbau erneuerbarer Energien (Erneuerbare-Energien-Gesetz), BGBl. I S. 3138, German Parliament. 2017.
2. Nitsch, J.; Pregger, T.; Scholz, Y.; Naegler, T.; Heide, D.; Luca de Tena, D.; Trieb, F.; Nienhaus, K.; Gerhardt, N.; Trost, T.; et al. *Long-Term Scenarios and Strategies for the Deployment of Renewable Energies in Germany in View of European and Global Developments: Summary of the Final Report*; Deutsches Zentrum für Luft und Raumfahrt (DLR): Kassel, Germany; Fraunhofer Institut für Windenergie und Energiesystemtechnik (IWES): Stuttgart, Germany; Ingenieurbüro für neue Energien (IFNE): Teltow, Germany, 2012.
3. Grim, J.; Nilsson, D.; Hansson, P.-A.; Nordberg, Å. Demand-Orientated Power Production from Biogas: Modeling and Simulations under Swedish Conditions. *Energy Fuels* **2015**, *29*, 4066–4075. [[CrossRef](#)]
4. Vogel, L.; Sugul, K.; Schünemeyer, F.; Krautkremer, B.; Hahn, H. *Final Report: Upgrading von Bestandsbiogasanlagen hin zu Flexiblen Energieerzeugern durch eine Bedarfsorientierte Dynamisierung der Biogasproduktion*; Fraunhofer-Institut für Windenergie und Energiesystemtechnik: Bremerhaven, Germany, 2018.
5. Mauky, E.; Weinrich, S.; Nägele, H.-J.; Jacobi, H.F.; Liebetrau, J.; Nelles, M. Model Predictive Control for Demand-Driven Biogas Production in Full Scale. *Chem. Eng. Technol.* **2016**, *39*, 652–664. [[CrossRef](#)]
6. Mauky, E.; Weinrich, S.; Jacobi, H.-F.; Nägele, H.-J.; Liebetrau, J.; Nelles, M. Demand-driven biogas production by flexible feeding in full-scale—Process stability and flexibility potentials. *Anaerobe* **2017**, *46*, 86–95. [[CrossRef](#)] [[PubMed](#)]

7. Weinrich, S.; Nelles, M. Critical comparison of different model structures for the applied simulation of the anaerobic digestion of agricultural energy crops. *Bioresour. Technol.* **2015**, *178*, 306–312. [[CrossRef](#)] [[PubMed](#)]
8. Batstone, D.J. Modelling and control in anaerobic digestion: Achievements and challenges. In Proceedings of the 13th World Congress on Anaerobic Digestion (AD 13), Santiago de Compostela, Spain, 25–28 June 2013.
9. Sun, H.; Yang, Z.; Zhao, Q.; Kurbonova, M.; Zhang, R.; Liu, G.; Wang, W. Modification and extension of anaerobic digestion model No.1 (ADM1) for syngas biomethanation simulation: From lab-scale to pilot-scale. *Chem. Eng. J.* **2021**, *403*, 126177. [[CrossRef](#)]
10. Gaida, D.; Wolf, C.; Bongards, M. Feed control of anaerobic digestion processes for renewable energy production: A review. *Renew. Sustain. Energy Rev.* **2017**, *68*, 869–875. [[CrossRef](#)]
11. Angelidaki, I.; Ellegaard, L.; Ahring, B.K. A mathematical model for dynamic simulation of anaerobic digestion of complex substrates: Focusing on ammonia inhibition. *Biotechnol. Bioeng.* **1993**, *42*, 159–166. [[CrossRef](#)]
12. Angelidaki, I.; Ellegaard, L.; Ahring, B.K. A comprehensive model of anaerobic bioconversion of complex substrates to biogas. *Biotechnol. Bioeng.* **1999**, *63*, 363–372. [[CrossRef](#)]
13. Bernard, O.; Hadj-Sadok, Z.; Dochain, D.; Genovesi, A.; Steyer, J.-P. Dynamical model development and parameter identification for an anaerobic wastewater treatment process. *Biotechnol. Bioeng.* **2001**, *75*, 424–438. [[CrossRef](#)]
14. Della Bona, A.; Ferretti, G.; Ficara, E.; Malpei, F. LFT modelling and identification of anaerobic digestion. *Control Eng. Pract.* **2015**, *36*, 1–11. [[CrossRef](#)]
15. Amon, T.; Amon, B.; Kryvoruchko, V.; Machmüller, A.; Hopfner-Sixt, K.; Bodiroza, V.; Hrbek, R.; Friedel, J.; Pötsch, E.; Wagentristsl, H.; et al. Methane production through anaerobic digestion of various energy crops grown in sustainable crop rotations. *Bioresour. Technol.* **2007**, *98*, 3204–3212. [[CrossRef](#)]
16. Baserga, U. Vergärung organischer Reststoffe in landwirtschaftlichen Biogasanlagen: Eidg. Forschungsanstalt für Agrarwirtschaft und Landtechnik, Tänikon, Schweiz. *FAT Ber.* **2000**, *546*, 1–9.
17. Seneesrisakul, K.; Sutabutr, T.; Chavadej, S. The Effect of Temperature on the Methanogenic Activity in Relation to Micronutrient Availability. *Energies* **2018**, *11*, 1057. [[CrossRef](#)]
18. Ruile, S.; Schmitz, S.; Mönch-Tegeder, M.; Oechsner, H. Degradation efficiency of agricultural biogas plants—a full-scale study. *Bioresour. Technol.* **2015**, *178*, 341–349. [[CrossRef](#)] [[PubMed](#)]
19. Czatzkowska, M.; Harnisz, M.; Korzeniewska, E.; Koniuszewska, I. Inhibitors of the methane fermentation process with particular emphasis on the microbiological aspect: A review. *Energy Sci. Eng.* **2020**, *8*, 1880–1897. [[CrossRef](#)]
20. Morozova, I.; Nikulina, N.; Oechsner, H.; Krümpel, J.; Lemmer, A. Effects of Increasing Nitrogen Content on Process Stability and Reactor Performance in Anaerobic Digestion. *Energies* **2020**, *13*, 1139. [[CrossRef](#)]
21. Kythreotou, N.; Florides, G.; Tassou, S.A. A review of simple to scientific models for anaerobic digestion. *Renew. Energy* **2014**, *71*, 701–714. [[CrossRef](#)]
22. Donoso-Bravo, A.; Mailier, J.; Martin, C.; Rodríguez, J.; Aceves-Lara, C.A.; Vande Wouwer, A. Model selection, identification and validation in anaerobic digestion: A review. *Water Res.* **2011**, *45*, 5347–5364. [[CrossRef](#)] [[PubMed](#)]
23. Ramachandran, A.; Rustum, R.; Adeloye, A.J. Review of Anaerobic Digestion Modeling and Optimization Using Nature-Inspired Techniques. *Processes* **2019**, *7*, 953. [[CrossRef](#)]
24. Naegele, H.-J.; Lindner, J.; Merkle, W.; Lemmer, A.; Jungbluth, T.; Bogenrieder, C. Effects of temperature, pH and O₂ on the removal of hydrogen sulfide from biogas by external biological desulfurization in a full scale fixed-bed trickling bioreactor. *Int. J. Agric. Biol. Eng.* **2013**, *6*, 69–81.
25. Naegele, H.-J.; Mönch-Tegeder, M.; Haag, N.L.; Oechsner, H. Effect of substrate pretreatment on particle size distribution in a full-scale research biogas plant. *Bioresour. Technol.* **2014**, *172*, 396–402. [[CrossRef](#)] [[PubMed](#)]
26. Ihaka, R.; Gentleman, R. R: A language for data analysis and graphics. *J. Comput. Graph. Stat.* **1996**, *5*, 299–314.
27. Gilbert, P.; Plummer, M. R Documentation—Package Stats Version 4.0.2: Acf[Stats]. Available online: <https://stat.ethz.ch/R-manual/R-patched/library/stats/html/acf.html> (accessed on 28 November 2020).
28. Booker, N. Chapter 8: Regression with Lagged Explanatory Variables. Available online: <https://silo.tips/download/chapter-8-regression-with-lagged-explanatory-variables> (accessed on 4 February 2021).
29. R Documentation. Lag a Time Series. Available online: <https://www.rdocumentation.org/packages/stats/versions/3.6.2/topics/lag> (accessed on 29 September 2020).
30. Hammer, B.; Frasco, M.; Le Dell, E. Package ‘Metrics’: Evaluation Metrics for Machine Learning. Available online: <https://cran.r-project.org/web/packages/Metrics/Metrics.pdf> (accessed on 4 February 2021).

4. Publikation 3: Model Predictive Control: Demand-orientated, Load-flexible, Full-scale Biogas Production

Celina Dittmer^a, Benjamin Ohnmacht^a, Johannes Krümpel^{a*} and Andreas Lemmer^a

^a Landesanstalt für Agrartechnik und Bioenergie, Universität Hohenheim, Garbenstrasse 9, 70599 Stuttgart, Germany

Informationen Publikation:

Publiziert: Microorganisms 2022, 10(4), 804

Empfangen: 23. Februar 2022

Akzeptiert: 8. April 2022

DOI: 10.3390/microorganisms10040804

Online: seit 12. April 2022 unter <https://www.mdpi.com/2076-2607/10/4/804>

Abstract

Biogas plants have the great advantage of producing electricity according to demand and are thus able to compensate fluctuating productions from weather dependent sources like wind power and photovoltaics. Prerequisite for flexible biogas plant operation is a suitable feeding strategy for an adjusted conversion from biomass into biogas. The present research investigation shows for the first time a practical, integrated model predictive control for load-flexible, demand-orientated biogas production, which allows application on almost all full-scale biogas plants with no or minor adjustments to available measurement technology. Over an experimental period of 36 days, biogas production from a full-scale plant was adjusted to the predicted electrical demand of a “real-world laboratory”. Results with a mean absolute percentage error (MAPE) of less than 20 % comparing biogas demand and production could be achieved consistently.

Key words: anaerobic digestion; feeding management; forecast; flexibilization; modeling; demand-driven biogas production



Article

Model Predictive Control: Demand-Orientated, Load-Flexible, Full-Scale Biogas Production

Celina Dittmer, Benjamin Ohnmacht, Johannes Krümpel * and Andreas Lemmer

State Institute of Agricultural Engineering and Bioenergy, University of Hohenheim, Garbenstrasse 9, 70599 Stuttgart, Germany; celina.dittmer@uni-hohenheim.de (C.D.); benjamin.ohnmacht@uni-hohenheim.de (B.O.); andreas.lemmer@uni-hohenheim.de (A.L.)

* Correspondence: j.kruempel@uni-hohenheim.de; Tel.: +49-711-459-24782

Abstract: Biogas plants have the great advantage that they produce electricity according to demand and can thus compensate for fluctuating production from weather-dependent sources such as wind power and photovoltaics. A prerequisite for flexible biogas plant operation is a suitable feeding strategy for an adjusted conversion of biomass into biogas. This research work is the first to demonstrate a practical, integrated model predictive control (MPC) for load-flexible, demand-orientated biogas production and the results show promising options for practical application on almost all full-scale biogas plants with no or only minor adjustments to the standardly existing measurement technology. Over an experimental period of 36 days, the biogas production of a full-scale plant was adjusted to the predicted electricity demand of a “real-world laboratory”. Results with a mean absolute percentage error (MAPE) of less than 20% when comparing biogas demand and production were consistently obtained.

Keywords: anaerobic digestion; feeding management; forecast; flexibilization; modeling; demand-driven biogas production



Citation: Dittmer, C.; Ohnmacht, B.; Krümpel, J.; Lemmer, A. Model Predictive Control: Demand-Orientated, Load-Flexible, Full-Scale Biogas Production. *Microorganisms* **2022**, *10*, 804. <https://doi.org/10.3390/microorganisms10040804>

Academic Editor: Sören Weinrich

Received: 23 February 2022

Accepted: 8 April 2022

Published: 12 April 2022

Publisher’s Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Sustainable, low-emission power generation requires a significant expansion of wind power and photovoltaic (PV) plants [1]. Therefore, a transformation of the power grids from a few centralized, controllable fossil or nuclear power plants to several million decentralized wind power and PV plants is needed [2]. Thus, electricity production is increasingly characterized by strong fluctuations that are decoupled from electricity demand.

In Germany, the gross electricity generation from wind power in 2020 was already about 23.5% and from PV about 9% of the total electricity generation [3]. One approach to permanently balance the resulting residual loads and sustainably secure the energy supply is to expand the power grids and increase storage capacities [4]. However, from a technical and economic point of view, these measures can only be implemented to a limited extent [5,6]. Another approach that is becoming increasingly important is the use of controllable producers that offer the advantage of power production driven by demand [7]. With the targets of the German Renewable Energy Act to cover 80% of the gross electricity supply by renewable energies by 2050, energy scenarios predict a need for 60 to 130 GW of controllable power plant capacity to ensure security of supply [8].

“Of the available renewable energy technologies—Apart from geothermal plants and hydropower stations—Bioenergy plants in general and biogas plants in particular, currently enable electricity production to be controlled” [9]. The load-flexible operation of biogas plants could balance both long-term seasonal and short-term fluctuations in electricity feed-in. However, of the approximately 9000 installed biogas-combined heat and power plants (CHP) in Germany, which is equivalent to about 5 GW [10], it is estimated that currently, only 150 biogas plants produce flexible energy [11].

Flexible operation of biogas plants requires technical adjustments, previously limited mainly to the expansion of gas storage capacities [12] and CHP performance [13]. Thus, short-term fluctuations in electricity demand can be balanced by decoupling biogas and electricity production. Nevertheless, the greatest flexibility can only be achieved if a suitable feeding strategy is used for demand-orientated conversion from biomass into biogas [9,12]. Then, biomass serves as a long-term energy storage before it is converted into biogas and further into electricity.

Concepts for feeding strategies were first investigated in laboratory experiments, mostly as batch processes [14,15]. The results obtained in these experiments cannot be adequately transferred to full-scale plants, since these are operated continuously and show entirely different conditions with respect to the population density of microorganisms and the structure of the microbial community, as well as homogeneous substrate availability [16]. Strategies for adapted feeding management at full-scale plants have previously been based on very extensive, complex models. In this context, various studies of models can be found in the literature [17–20], which primarily aimed at improving process stability and efficiency. Model predictive control (MPC) is particularly suitable for adjusting the biogas plant operation to specified future setpoints [21]. In this process, an internal dynamic model is used to calculate the future behavior of the process as a function of input signals [22]. Models specifically focusing on energy demand-driven biogas production have been developed by Grim, Mauky and Peters et al. [22–24], whereas Mauky et al. [21] use MPC to feed the process + to follow a predetermined schedule for gas utilization. All these approaches are based on the well-known Anaerobic Digestion Model No. 1 (ADM1), published by Batstone [25]. The ADM1 is highly complex since it takes into account the parameters of all biochemical process steps (hydrolysis, acidogenesis, acetogenesis, methanogenesis) as well as physicochemical processes (ion association/dissociation and gas-liquid transfer, etc.) [23] which must be determined or estimated individually for each digester and each of the substrates used. Although the complexity of ADM1 has already been significantly reduced by Weinrich and Mauky et al. [21,24,26], a large number of individual input parameters are still required. These primarily include the composition and degradation behavior, respectively, and the gas formation kinetics of the substrates used. All parameters have to be carefully adjusted to the specific full-scale plant and actual process state [27,28]. In addition, there is a lack of robust measurement technology, that would make the main process states observable, or extensive equipment for process monitoring is usually not available at full-scale plants [29].

The aim of this research is to develop a practical, integrated MPC for load-flexible, demand-orientated biogas production, which can be used on nearly all full-scale biogas plants with no or only minor adjustments to available measurement technology. For this purpose, the application of our previously evaluated forecast model [30] and the simulation model we developed [28] in combination with a new controller is demonstrated here for the first time in full-scale. Here, the biogas production of the full-scale plant is aligned with the predicted power demand of a “real-world laboratory”. The performance is evaluated in terms of adaptability to changing biogas demand profiles.

2. Materials and Methods

2.1. Experimental Setup

The present study was carried out at the full-scale research biogas plant of the University of Hohenheim, located at “Unterer Lindenhof” in Eningen unter Achalm, Southwest Germany. As described in detail by Dittmer et al. [30], this site functions as a “real-world laboratory” with an agricultural area of almost 180 ha, livestock, laboratory, and technical rooms, and several employees, interns, and apprentices. The energy demand of the “Unterer Lindenhof” is about 750,000 kWh per year and roughly corresponds to that of a small village with 150 inhabitants.

The biogas plant consists of two continuous stirred-tank reactors and a secondary digester, each with a networking volume of 850 m³. Both digesters are covered with insulated

concrete and are operated in the mesophilic range at 43 ± 4 °C. Two double-membrane gas storages of 300 m³ and 1600 m³, installed on the secondary digester and the digestate storage, respectively, serve as buffers for the produced biogas prior to its utilization by a CHP-unit with an installed electrical power of 355 kW. A more detailed description of the setup of the entire research biogas plant can be found in Naegele et al. [31,32].

For this study, one of the two primary digesters was used. The digester is equipped with a submersible motor mixer and an inclined agitator unit. The mixing time during the experiment was set so that both mixing devices were operated only two minutes before and after feeding, as well as during feeding. Solid substrates were supplied by a vertical mixer feeding system with a capacity of about 20 tons (Biogas Höre GmbH, Orsingen-Nenzingen, Germany, type Höre Combi 4500). Weighing cells recorded the quantity of substrates used. Liquid substrates were added with a progressive cavity pump and measured with a flow meter (Proline Promag 50; Endress+Hauser, Weil am Rhein, Germany). The volumetric gas flow was detected directly at the gas outlet of the digester by a flow meter with an oscillating measuring method (hot wire sensor, company Esters Elektronik GmbH, type GD300). Temperature and pressure were recorded to calculate the biogas volume produced under standard conditions (1013 mbar, 273 K), which are continuously available in m³ h⁻¹.

The research biogas plant is equipped with a central plant control (CPC) unit for data collection, storage, and evaluation. Data from the CPC unit is transferred to a relational database for further consolidation, transfer, and processing. Individual programs such as the forecast modules and feed-manager query the database and upload the results of the calculations back for further analysis. Exported feeding schedules from the database can then be loaded into the CPC unit.

All programming for visualization, modeling, and simulation was done using the programming language R [33]. Specific packages are referenced below wherever appropriate.

2.2. Sampling and Analysis

During the experimental period, samples of all substrates used and the digestate were taken three times a week (Mondays, Wednesdays, Fridays) and analyzed in the biogas laboratory of the University of Hohenheim. Samplings were carried out in accordance with the guideline 4630 of the Society for Energy and Environment, documented in [34].

The substrates used and the samples from the digester were analyzed for their dry matter (DM) and organic dry matter (oDM) content. The procedure for this analysis was carried out according to standard methods and is described in detail in [35]. Further, the samples from the digester were analyzed for buffer capacity (FOS/TAC), which was carried out according to the VDLUFA standard methods described in [36]. In addition, the intermediates were investigated by determining the content of acetic, propionic, butyric, valeric, and caproic acids using a gas chromatograph (GC, type CP3800 with flame ionization detector, WCOT Fused Silica capillary column, Agilent Technologies Germany GmbH, Böblingen, Germany).

The results were used to determine major deviations from standard conditions and to calculate the organic loading rate (OLR), which refers to the amount of organic material per unit reactor volume per day.

2.3. Model Predictive Control

As illustrated in the schematic diagram in Figure 1, the MPC for load-flexible, demand-orientated biogas production is based on three key components:

1. Forecast of the future power demand for 48 h of the “real-world laboratory”.
2. Forecast of the biogas demand, derived from the power demand forecast.
3. Feeding management model for planning the corresponding substrate-supply.




Figure 1. Schematic representation of the model predictive control (MPC) with showing and classifying the three key components: forecast of future power demand, forecast of biogas demand, feeding management model.

2.3.1. Power Demand Forecast

The forecasting model developed by Dittmer et al. [30] was used to predict the power demand of the “real-world laboratory”. For this purpose, the historical power consumption data of the last four weeks was retrieved daily to forecast the next 48 h. The model is based on a time series analysis, using correlations of past values, trends, and seasonality to predict future values.

2.3.2. Biogas Demand Forecast

Using fixed conversion factors, the resulting time series of biogas demand was determined from the power demand according to Equation (1). It is the declaration of the required raw biogas with approx. 60% methane content. In addition, a scaling factor and the number of digesters were applied to scale the “real-world laboratory” to the size of the actual CHP unit and to simulate the adjustment of the biogas demand to larger or smaller consumption units to test different settings of the model.

$$D_t^s = \left(\frac{P_{fcst} \cdot f_s}{\eta_{BHKW}} \right) / n \quad (1)$$

The parameters are defined as:

- D_t^s biogas demand in m^3 with index t for the time and s stands for the series
- P_{fcst} forecasted power demand in kWh
- f_s scaling factor
- η_{BHKW} fixed efficiency of CHP of 0.35
- $f_{\text{kWh_m}^3}$ fixed conversion factor from kWh to m^3 -of 5.5 kWh per m^3
- n number of digesters

2.3.3. Feeding Management Model

The workflow of the feeding management model is as follows:

1. Random construction of feeding timetables for the next 48 h.
2. Simulation of biogas production for each feeding timetable.
3. Selection of the timetable fitting best the demand.

2.3.4. Randomly Constructed Feeding-Timetables (1.)

Considering the technical limitations of the full-scale biogas plant and to simplify the process in general, only feeding increments of 500 kg were allowed in this experiment. The 48-h horizon was divided into 5-min intervals. For each interval, a binomial distribution was generated (0 or 1), corresponding to a feeding event of 500 kg or no feeding. Additionally, a “Probability of success” (POS) was introduced to determine the likelihood of the outcome to feed. The POS was calculated each day based on the total biogas demand in the next 48 h and the historical specific biogas-yield of the last three weeks (see Equations (2) and (3)).

$$\text{Specific biogas yield} = \frac{\overline{b_{hist}}}{\overline{s_{hist}}} \quad (2)$$

$$\text{POS} = \frac{\sum D_t^s}{\text{Specific biogas yield} \cdot s_{fixed}} / 576 \quad (3)$$

The parameters are defined as:

- $\overline{b_{hist}}$ mean biogas production over the last 500 h in $\text{m}^3 \text{h}^{-1}$
- $\overline{s_{hist}}$ mean substrate feeding over the last 500 h in kg h^{-1}
- $\sum D_t^s$ total biogas demand over the next 48 h in m^3
- s_{fixed} fixed substrate quantity of 500 kg
- 576 related to the number of 5-min intervals during 48 h

The POS is used to reduce the total number of random timetables, or in other words, it creates a set of feeding timetables that meet the requirements of the total biogas needed in the next 48 h, rather than creating entirely random timetables.

Finally, the 5-min intervals with their corresponding binomial values are aggregated into an hourly time series.

In total, 1500 timetables are created for the following 48 h, on each day of the experiment.

2.3.5. Simulation of Biogas Production (2.)

For each of the 1500 randomly constructed feeding plans, the resulting biogas production is simulated. For this, the novel simulation model developed by Dittmer et al. [28] is used. The model is based on correlations between substrate supply and biogas production, which are determined over a training horizon of the last 500 h of observation. Including the recent feedings and the new random-timetables, the resulting biogas production can be simulated by Equation (4) [35]:

$$Y_t = \alpha + \beta_0 X_t + \beta_1 X_{t-1} + \dots + \beta_k X_{t-k} + \varepsilon_t \quad (4)$$

The parameters of the multiple regression model are defined as:

- Y dependent variable
- t point in time
- X independent variable
- α intercept
- β slope
- ε_t error term
- k lag order

2.3.6. Select the Best Feeding-Timetable (3.)

The appropriate feeding plan is selected by comparing the simulated biogas production to the biogas demand, using the symmetric mean absolute percentage error (SMAPE) [37]. The SMAPE is defined as follows:

$$\text{SMAPE} = \frac{|D_t^s - z_t^s|}{(|D_t^s| + |z_t^s|)} \quad (5)$$

The parameters are defined as:

- z_t^s simulated values
- t point in time
- s for series
- D_t^s is defined in Equation (1)

The feeding-timetable with the lowest SMAPE is selected, uploaded to the database, and read into the plant-control to be executed.

2.4. Practical Implementation, Experimental Phases

The daily imported feeding plan contains the specification of the time of the day when feeding is to take place and the respective quantity of solid substrates to be supplied into the digester. To ensure proper reading and processing of all required data, a time window of three hours was specified during which no feedings were permitted in the feeding plan. This time window was also used to fill the vertical mixer feeding system with sufficient solid substrates to ensure that at least about 12 tons were in stock. This ensured that there was always enough material for all feedings over the next 24 h. With this exception of the daily supply of the feeding system, all process steps of the experiment ran completely automatically.

The experiment was divided into four phases in which different settings of the model were created and tested. Prior to the experimental phases, a 29-day start-up phase was conducted to optimize the integration of the model into the CPC and the automation of the process steps. Furthermore, stable digestion conditions were ensured by adjusting the feeding quantities as required in the initial experimental phase and, accordingly, maintaining an approximately constant OLR. Data collected during this phase were not included in the evaluation of the model.

During the four experimental phases, the biogas demand was scaled alternately to half and back to full demand, to test the suitability and limitations of the model with regard to major fluctuations in electricity demand. This was done by setting the scaling factor f_s to the value 4 or 2 in Equation (6).

$$D_t^s = \left(\frac{P_{fcst} \cdot f_s}{\eta_{BHKW}} \right) / n \quad (6)$$

Accordingly, the first phase was conducted with a high demand and covered 360 h/15 days. In the second phase, the demand was reduced by over 216 h/9 days. Subsequently, in a third phase, the demand was increased again over 168 h/7 days and finally halved again over 120 h/5 days (fourth phase).

2.5. Evaluation of the MPC

MPC was evaluated using various accuracy parameters. These were used to assess the average quality of the results per day. In addition to evaluating the overall model (biogas demand versus production), the substeps, such as simulation versus demand and simulation versus actual biogas production, were also assessed.

First, the SMAPE was calculated, since it is also used as a selection criterion in the model itself. The calculation can be found in Equation (7). Although other parameters are used in this context, for which reason the index Q is used:

$$\text{SMAPE}_Q = \frac{1}{E} \sum_{t=1}^E \frac{|actual - predicted|}{(|actual| + |predicted|)} \cdot 100\% \quad (7)$$

The parameters are defined as:

- *actual* set point in $\text{m}^3 \text{h}^{-1}$
- *predicted* modeled value in $\text{m}^3 \text{h}^{-1}$

In Equation (7), E indicates the number of observations, which here always includes 24, since the parameter is considered per day.

Furthermore, the commonly used mean absolute percentage error (MAPE) was applied [37]. The parameters and abbreviations are the same as in Equation (8).

$$\text{MAPE} = \frac{1}{E} \sum_{t=1}^E \left| \frac{actual - predicted}{actual} \right| \cdot 100\% \quad (8)$$

In addition, the mean absolute error (MAE) and the positive and negative deviations from the actual and predicted values of the overall model (biogas demand versus production) were used as parameters for the evaluation. For this purpose, the R function *mae()* from the R package *metrics* [37] and differences between actual and predicted values were calculated. These daily deviations are particularly relevant for the evaluation of the compensation of over- or underproduction by the gas storage.

3. Results and Discussion

3.1. Power Demand Forecast and Derived Biogas Demand

Derived from the projected electricity demand, Figure 2 shows the hourly biogas demand over the entire period of the experiment.




Figure 2. Hourly biogas demand profile over the entire test period, derived from the electricity demand of the “real-world laboratory”. The vertical grey lines identify start and end of the four experimental phases. The weekends are marked with dotted lines and “w”.

Variations resulting from day/night and weekday/weekend cycles were observed, which is typical for the energy demand of a site, as described in Dittmer et al. [30]. At our

site, demand during the day largely exceeds demand during the night, and less energy is consumed during weekends than on weekdays. The largest variation in biogas demand within one hour was observed in the transition from one phase to the other, with differences of nearly $45 \text{ m}^3 \text{ h}^{-1}$ in each case. This leap is relatively high compared to the results of Mauky et al. [21] with, for example, a difference of $20 \text{ m}^3 \text{ h}^{-1}$ only. The largest spread within one day was 95 m^3 on day 25.

The mean biogas demand in the first experimental phase was $107 \text{ m}^3 \text{ h}^{-1}$, with a maximum of $170 \text{ m}^3 \text{ h}^{-1}$ and a minimum of $40 \text{ m}^3 \text{ h}^{-1}$. This first experimental phase ended after day 15 and represented the longest phase. Since this phase covered two whole weeks, the different demands of weekdays and weekends were sufficiently represented.

The second experimental phase shows the biogas demand over nine days with a weekend in the middle. The mean demand during this phase was $51 \text{ m}^3 \text{ h}^{-1}$, while maximum and minimum were $95 \text{ m}^3 \text{ h}^{-1}$ and $36 \text{ m}^3 \text{ h}^{-1}$, respectively. Thus, the biogas demand was reduced by about 50% compared to the first experimental phase. This reduction in demand should demonstrate how reliably and quickly biogas production can be significantly reduced.

In the third experimental phase, the biogas demand was increased again, with a mean demand of $100 \text{ m}^3 \text{ h}^{-1}$ during a period of seven days and maximum and minimum values of $146 \text{ m}^3 \text{ h}^{-1}$ and $47 \text{ m}^3 \text{ h}^{-1}$, respectively. This phase was intended to show the extent to which a rapid significant increase in biogas production is possible.

For reproducibility, the last phase over five days represents again a reduced demand with a mean demand of $49 \text{ m}^3 \text{ h}^{-1}$ and a maximum and minimum of $68 \text{ m}^3 \text{ h}^{-1}$ and $37 \text{ m}^3 \text{ h}^{-1}$, respectively.

3.2. Feeding Management Model

3.2.1. Calculation Results

36 individual feeding schedules with a 48 h time horizon were calculated for each day of the entire experimental period and are shown in Figure 3 with the corresponding biogas simulations.




Figure 3. Biogas demand and simulated biogas production, as well as the associated daily feeding schedules in hourly resolution over the entire experimental period. The vertical grey lines identify start and end of the four experimental phases.

The lower part of Figure 3 shows the planned feeding schedules. Remarkably, even in the phases with higher biogas demand, 500 kg of substrate per hour should be used in most cases, but 1000–3000 kg in rare cases. However, based on the boundary conditions of the model, a maximum quantity of 6000 kg h^{-1} would be possible. This maximum feeding rate

was chosen due to technical limitations of the biogas plant (solid feeding system, stirring technology, etc.) and the OLR. In this respect, adjustments in the model might be necessary when it is adapted to other biogas plants.

The simulated biogas production, especially in the first experimental phase, closely followed the biogas demand with only a few deviations. The fact that especially the first phase provides comparatively good results is also demonstrated by the accuracy parameters in Table 1, with a mean daily MAPE of 7.3%. This can be explained, among other things, by the fact that the biogas plant was already operated with similar conditions in terms of average biogas demand, OLR, and substrate mix in the 29-day start-up phase. This allowed the simulation model, which uses historical data as shown in Equation (4), to adapt to the conditions [28].

Table 1. Mean values of accuracy parameters SMAPE [%], MAPE [%], and MAE [m³] to evaluate the quality of simulation results.

	Phase 1	Phase 2	Phase 3	Phase 4
Time Period	Day 1–15	Day 16–24	Day 25–31	Day 32–36
SMAPE [%]	7.4 ± 1.7	20.3 ± 11.6	10.1 ± 2.5	12.5 ± 6.0
MAPE [%]	7.3 ± 1.7	24.9 ± 16.0	9.6 ± 2.0	14.5 ± 9.2
MAE [m ³]	8.1 ± 2.1	11.6 ± 6.9	9.6 ± 1.5	7.0 ± 4.5

The third phase, which also represents high biogas demand, yielded good results as well. Here, the average daily MAPE was 9.6%. In particular, the transitions to an experimental phase with lower demand were characterized by larger deviations. This suggests that the decrease in biogas production is slower to realize than the increase, which is a result of the slow degradability of the substrates. However, this is taken into account by the simulation model [28]. Overall, the largest deviations were observed in phase two, with an average MAPE of 25%. However, after day 4 of experimental phase two, the deviations decrease significantly. Phase 4, in turn, shows better values with an average MAPE of 15%.

A major reason for the relatively poor simulation results in phase two is the use of historical biogas production data by the model. As described in Dittmer et al. [28], the results of the simulations are based on Equation 4 with the data of the biogas production and the feeding amounts of the last 500 h. Since the biogas production during this period was never as low as in phase two, the model has to level off first. In this case, the model will first output the value of the intercept α . This will only reach the required low values when the historical data on which the calculation is based also include lower values. Therefore, the situation is different in phase four, where training data of a similarly low demand of phase two are already included and thus, accurate simulation results could be obtained much faster.

3.2.2. Implementation Results

The results of the implemented procedure for the feeding management are presented in Figure 4 in red for the produced biogas and the actual substrate feeding.

During the first experimental phase, the biogas produced closely matched with the simulated data and the biogas demand profile, which is also confirmed by the accuracy parameters in Table 2, with a mean daily MAPE of the simulation results of 10.2%. The only major deviation around the 9th and 10th day of the experiment can be explained by planned but not executed feedings, as can be seen in the lower part of Figure 4. These feedings were not executed because of technical problems in the control system of the biogas plant. The same problem was also observed in phase three around days 29 and 30, resulting in a mean MAPE in this phase of 18.8%.




Figure 4. Biogas demand, simulated biogas production and biogas produced, as well as the associated daily feeding schedules and the feedings performed in hourly resolution over the entire experimental period.

Table 2. Mean values of accuracy parameters SMAPE [%], MAPE [%] and MAE [m^3] as well as the difference between biogas demand and production (diff. [m^3]) for evaluating the quality of simulation (comparison data of the simulation and the biogas produced) [Sim] and of the final results of the whole feeding management model (comparison data biogas demand and the biogas produced) [Feed].

	Phase 1	Phase 2	Phase 3	Phase 4
Time Period	Day 1–15	Day 16–24	Day 25–31	Day 32–36
SMAPE [%]				
[Sim]	10.3 ± 4.2	31.3 ± 10.3	21.6 ± 8.3	11.3 ± 4.0
[Feed]	11.7 ± 4.6	24.0 ± 3.8	25.1 ± 9.0	17.2 ± 6.4
MAPE [%]				
[Sim]	10.2 ± 3.2	26.3 ± 7.4	18.8 ± 6.4	11.7 ± 4.3
[Feed]	11.6 ± 3.9	23.0 ± 5.3	21.5 ± 6.3	19.9 ± 9.9
MAE [m^3]				
[Sim]	11.2 ± 4.7	16.1 ± 4.9	17.4 ± 5.6	6.4 ± 1.7
[Feed]	12.5 ± 4.6	11.7 ± 2.4	20.7 ± 5.2	9.8 ± 5.3
diff. [m^3]				
[Feed]	16.8 ± 212.7	-147.12 ± 195.4	-432.21 ± 277.9	156.14 ± 203.7

The experimental phases two and four with low biogas demand showed a mean MAPE value of 26.3% and 11.8%, respectively. In particular, the second phase showed slightly poorer results. However, this can be justified, by the fact that the simulation results already deviated clearly from the biogas demand profile, as discussed in the previous section. On the other hand, in line with the regular operation of the full-scale biogas plant and thus, regardless of the feeding management, daily feedings of 6000 kg of liquid manure were carried out during the experiment. These resulted in an increase in biogas production that could not be accounted for by the model, since liquid manure feeding is not considered as a parameter [28]. Consequently, the liquid manure supply was distributed more evenly throughout the day, resulting in better simulation results from day 21 onwards, as shown in Figure 4 and confirmed by the accuracy parameters in Table 2.

In summary, biogas production could be simulated sufficiently well with an average daily MAPE of 16.1% over the entire experimental period. These results are consistent

with the findings of Dittmer et al. [28], who reported an average MAPE of 14–18% when evaluating 366 simulations.

As can be seen in Figure 4, feedings could be carried out as planned, with the exceptions mentioned above. In order to evaluate the present model in more detail, further experiments with a more variable substrate composition might be useful. Solid substrates were used in the composition of 41% solid manure, 52% corn silage, and 7% grass silage on average during the experimental period. The liquid manure input, which is not taken into account in the model, also accounts for 58% of the total substrate mass used. This represents more than 50% of the total feed. This again justifies the significant increase in biogas production when the liquid manure was batched and without simultaneous feeding of solid substrates. However, due to the relatively low biogas yield [38] and the results of Dittmer et al. [28], it is justified not to include liquid manure feeding as an additional parameter in the simulation model.

To evaluate the stability of the process conditions during the experimental period, the OLR was calculated, which was on average 1.65 kg dry organic matter per cubic meter of digester volume per day. This value tends to be low with regard to the potential use of a biogas plant of this size [39]. This can be explained by the fact that the biogas demand profile was generally set low during the experimental period and was also reduced twice by 50% in each case. Therefore, high dosages were also rarely planned in the feeding schedule and the maximum of 6000 kg per hour was never provided. The results suggest that, with regard to OLR, a larger biogas demand could also be met by higher or more frequent substrate dosages.

Considering the quality of the final results of the feeding management model, balancing biogas demand and production resulted in an average daily MAPE of 17.6% over the entire experimental period. Phase one showed the best results with a low MAPE of 11.6% on average, while the latter three phases showed average MAPE values between 20–23%. The actual difference between biogas demand and production was calculated as a further quality parameter. Here, it was assumed that the biogas demand, which was derived from the forecasted electricity demand, actually occurred in this way (no forecast errors). Positive values indicate overproduction, whereas negative values indicate insufficient biogas production. On day 30 of the experimental period, the lowest negative value was recorded with a difference of 714.9 m³. However, this resulted from the technical problems already explained above and not from the unsatisfactory results of the model. The second highest deviation of −640.1 m³ was calculated for day 25. Maximum overproduction was reached on day 32 with 486.1 m³. On average over the entire experimental period, 92.1 m³ of biogas per day were underproduced.

In particular, the consideration of the over- and underproduction of biogas during the experiment serves as an estimate for the required gas storage capacities in the case of demand-oriented biogas production using the model presented. Based on the research for a full-scale biogas plant, the total gas storage volume is 950 m³ per digester (two double membrane gas storages with 300 m³ and 1600 m³ capacity are available for both digesters). Accordingly, both under- and overproduction could be compensated in this case. However, this assumes an almost empty gas storage at the same time of maximum overproduction and vice versa. This is a crucial factor since the upgrading of the gas storage capacity is technically limited and costly, as discussed in [9,40,41]. In this context, a potential improvement of the present model would be to include the gas storage level in the calculation of the predicted biogas demand by adjusting it downwards or upwards accordingly. This is relatively simple and could possibly lead to a further reduction of the required gas storage capacity.

Moreover, further research could aim to integrate CHP-control into the MPC to represent the complete full-scale biogas plant. For example, this would allow biogas production to be based not only on electricity demand, but also on the thermal demand of a site. This would include an additional algorithm for the continuous calculation of adjusted CHP schedules. Furthermore, large-scale experiments of the MPC on several full-scale

biogas plants would be useful to further verify the present results. Also, a much longer experimental period would be beneficial, especially in view of the changing substrates used and large fluctuations in the biogas demand profile.

4. Conclusions

The future operation of biogas plants should be demand-orientated. Therefore, a new MPC is presented, which is highly practicable for the first time and consistently yields results with a MAPE of less than 20% comparing biogas demand and production. Over an experimental period of 36 days, the biogas production of a full-scale plant was adjusted to the actual electricity demand of a “real-world laboratory”, which was predicted from the demand during 48 h in advance. The calculation of the feeding plans used a type of Monte Carlo algorithm followed by a simulation of the expected biogas production. The most suitable feeding plan contains only the information about the amount of solid substrates to be used and the respective time of feeding. Thus, the presented MPC differs significantly from all previous models, since it requires very few input parameters. Specifically, only the measured actual electricity demand (using regularly installed electricity meters), the quantity of solid substrates fed in, regardless of their composition, (e.g., weighing cells under the solids feeder), and for the biogas produced (e.g., flow meters) need to be available. Therefore, the results show promising options for practical application nearly all full-scale biogas plants with no or only minor adjustments of the technical setup.

Author Contributions: C.D.: conceptualization, methodology, software, validation, formal analysis, investigation; B.O.: software, investigation, data curation, writing—review & editing; J.K.: project administration, writing—review & editing, software, data curation; A.L.: supervision, project administration, funding acquisition, writing—review & editing, resources. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the German Federal Ministry of Food and Agricultural, through the Fachagentur Nachwachsende Rohstoffe e.V., under the trademark 22404717.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Conflicts of Interest: The authors declare no conflict of interest.

References

- Shivakumar, A.; Dobbins, A.; Fahl, U.; Singh, A. Drivers of renewable energy deployment in the EU: An analysis of past trends and projections. *Energy Strategy Rev.* **2019**, *26*, 100402. [CrossRef]
- Mika, B.; Goudz, A. Blockchain-technology in the energy industry: Blockchain as a driver of the energy revolution? With focus on the situation in Germany. *Energy Syst.* **2021**, *12*, 285–355. [CrossRef]
- Federal Ministry for Economic Affairs and Energy. Time Series for the Development of Renewable Energy Sources in Germany 1990–2020: Based on Statistical Data from the Working Group on Renewable Energy-Statistics (AGEE-Stat). Available online: https://www.erneuerbare-energien.de/EE/Redaktion/DE/Downloads/development-of-renewable-energy-sources-in-germany-2020.pdf?__blob=publicationFile&v=29 (accessed on 6 November 2021).
- Zsiborács, H.; Pintér, G.; Vincze, A.; Birkner, Z.; Baranyai, N.H. Grid balancing challenges illustrated by two European examples: Interactions of electric grids, photovoltaic power generation, energy storage and power generation forecasting. *Energy Rep.* **2021**, *7*, 3805–3818. [CrossRef]
- Senkpiel, C.; Hauser, W. Systemic Evaluation of the Effects of Regional Self-Supply Targets on the German Electricity System Using Consistent Scenarios and System Optimization. *Energies* **2020**, *13*, 4695. [CrossRef]
- Lund, P.D.; Lindgren, J.; Mikkola, J.; Salpakari, J. Review of energy system flexibility measures to enable high levels of variable renewable electricity. *Renew. Sustain. Energy Rev.* **2015**, *45*, 785–807. [CrossRef]
- Forschungsstelle für Energiewirtschaft. Smart Meter, Prosumer, Flexumer—Wie Digitalisierung die Rolle von Verbrauchern ändert. Available online: <https://www.ffe.de/veroeffentlichungen/smart-meter-prosumer-flexumer-wie-die-digitalisierung-die-rolle-von-verbrauchern-veraendert/> (accessed on 20 December 2021).

8. Gesetz über den Ausbau erneuerbarer Energien (Erneuerbare-Energien-Gesetz), BGBl. I S. 3138: EEG, 2017, EEG 2021—Gesetz für den Ausbau erneuerbarer Energien. Available online: https://www.gesetze-im-internet.de/eeg_2014/BJNR106610014.html (accessed on 22 February 2022).
9. Barchmann, T.; Mauky, E.; Dotzauer, M.; Stur, M.; Weinrich, S.; Jacobi, H.F.; Liebetrau, J.; Nelles, M. Erweiterung der Flexibilität von Biogasanlagen—Substratmanagement, Fahrplansynthese und ökonomische Bewertung. *Agric. Eng.* **2016**, *71*, 233–251.
10. Fachverband Biogas. *Biogas Branchenzahlen 2020 und Prognose der Branchenzahlen 2021*; Fachverband Biogas: Freising, Germany, 2021.
11. Daniel-Gromke, J.; Kornatz, P.; Dotzauer, M.; Stur, M.; Densyenko, V.; Stelzer, M.; Hahn, H.; Krautkremer, B.; von Bredow, H.; Antonow, K. Leitfaden Flexibilisierung der Strombereitstellung von Biogasanlagen (LF Flex): Abschlussbericht. Available online: https://www.dbfz.de/fileadmin/user_upload/Referenzen/Studien/20191108_LeitfadenFlex_Abschlussbericht.pdf (accessed on 22 February 2022).
12. Mauky, E.; Weinrich, S.; Jacobi, H.-F.; Nägele, H.-J.; Liebetrau, J.; Nelles, M. Demand-driven biogas production by flexible feeding in full-scale—Process stability and flexibility potentials. *Anaerobe* **2017**, *46*, 86–95. [\[CrossRef\]](#)
13. Fachagentur Nachwachsende Rohstoffe. Flexibilisierung von Biogasanlagen. Available online: https://www.fnr.de/fileadmin/allgemein/pdf/broschueren/Broschuere_Flexibilisierung_Biogas_Web.pdf (accessed on 22 February 2022).
14. Mulat, D.G.; Jacobi, H.F.; Feilberg, A.; Adamsen, A.P.S.; Richnow, H.-H.; Nikolausz, M. Changing feeding regimes to demonstrate flexible biogas production: Effects on process performance, microbial community structure, and methanogenesis pathways. *Appl. Environ. Microbiol.* **2016**, *82*, 438–449. [\[CrossRef\]](#)
15. Lv, Z.; Leite, A.F.; Harms, H.; Richnow, H.H.; Liebetrau, J.; Nikolausz, M. Influences of the substrate feeding regime on methanogenic activity in biogas reactors approached by molecular and stable isotope methods. *Anaerobe* **2014**, *29*, 91–99. [\[CrossRef\]](#)
16. Oechsner, H.; Huelsemann, B.; Hernandez, C.M.M. Transferability of results from laboratory scale to biogas plants at real scale. *Rev. Cienc. Técnicas Agropecu.* **2020**, *29*, 93–103.
17. Waewsak, C.; Nopharatana, A.; Chaiprasert, P. Neural-fuzzy control system application for monitoring process response and control of anaerobic hybrid reactor in wastewater treatment and biogas production. *J. Environ. Sci.* **2010**, *22*, 1883–1890. [\[CrossRef\]](#)
18. Méndez-Acosta, H.O.; Campos-Delgado, D.U.; Femat, R.; González-Alvarez, V. A robust feedforward/feedback control for an anaerobic digester. *Comput. Chem. Eng.* **2005**, *29*, 1613–1623. [\[CrossRef\]](#)
19. Scherer, P.; Lehmann, K.; Schmidt, O.; Demirel, B. Application of a fuzzy logic control system for continuous anaerobic digestion of low buffered, acidic energy crops as mono-substrate. *Biotechnol. Bioeng.* **2009**, *102*, 736–748. [\[CrossRef\]](#)
20. Aguilar-Garnica, E.; Dochain, D.; Alcaraz-González, V.; González-Álvarez, V. A multivariable control scheme in a two-stage anaerobic digestion system described by partial differential equations. *J. Process. Control.* **2009**, *19*, 1324–1332. [\[CrossRef\]](#)
21. Mauky, E.; Weinrich, S.; Nägele, H.-J.; Jacobi, H.F.; Liebetrau, J.; Nelles, M. Model Predictive Control for Demand-Driven Biogas Production in Full Scale. *Chem. Eng. Technol.* **2016**, *39*, 652–664. [\[CrossRef\]](#)
22. Camacho, E.F.B.C. (Ed.) *Model Predictive Control: Advanced Textbooks in Control and Signal Processing*; Springer: London, UK, 2007; ISBN 978-1-85233-694-3.
23. Hangyu, S.; Ziyi, Y.; Qing, Z.; Malikakhon, K.; Ruihong, Z.; Guangqing, L.; Wen, W. Modification and extension of anaerobic digestion model No.1 (ADM1) for syngas biomethanation simulation: From lab-scale to pilot-scale. *Chem. Eng. J.* **2021**, *403*, 126177.
24. Vergote, T.L.; Vanrolleghem, W.J.; Van der Heyden, C.; De Dobbelaere, A.E.; Buysse, J.; Meers, E.; Volcke, E.I. Model-based analysis of greenhouse gas emission reduction potential through farm-scale digestion. *Biosyst. Eng.* **2019**, *181*, 157–172. [\[CrossRef\]](#)
25. Batstone, D.; Keller, J.; Angelidaki, I.; Kalyuzhnyi, S.; Pavlostathis, S.; Rozzi, A.; Sanders, W.; Siegrist, H.; Vavilin, V. *Anaerobic Digestion Model No 1 (ADM1)*; IWA Publishing: London UK, 2002.
26. Weinrich, S.; Nelles, M. Systematic simplification of the Anaerobic Digestion Model No. 1 (ADM1)—Model development and stoichiometric analysis. *Bioresour. Technol.* **2021**, *333*, 125124. [\[CrossRef\]](#)
27. Donoso-Bravo, A.; Mailier, J.; Martin, C.; Rodríguez, J.; Aceves-Lara, C.A.; Vande Wouwer, A. Model selection, identification and validation in anaerobic digestion: A review. *Water Res.* **2011**, *45*, 5347–5364. [\[CrossRef\]](#)
28. Dittmer, C.; Krümpel, J.; Lemmer, A. Modeling and Simulation of Biogas Production in Full Scale with Time Series Analysis. *Microorganisms* **2021**, *9*, 324. [\[CrossRef\]](#)
29. Gaida, D.; Wolf, C.; Bongards, M. Feed control of anaerobic digestion processes for renewable energy production: A review. *Renew. Sustain. Energy Rev.* **2017**, *68*, 869–875. [\[CrossRef\]](#)
30. Dittmer, C.; Krümpel, J.; Lemmer, A. Power demand forecasting for demand-driven energy production with biogas plants. *Renew. Energy* **2021**, *163*, 1871–1877. [\[CrossRef\]](#)
31. Naegele, H.-J.; Lemmer, A.; Oechsner, H.; Jungbluth, T. Electric Energy Consumption of the Full Scale Research Biogas Plant “Unterer Lindenhof”: Results of Longterm and Full Detail Measurements. *Energies* **2012**, *5*, 5198–5214. [\[CrossRef\]](#)
32. Naegele, H.-J.; Lindner, J.; Merkle, W.; Lemmer, A.; Jungbluth, T.; Bogenrieder, C. Effects of temperature, pH and O₂ on the removal of hydrogen sulfide from biogas by external biological desulfurization in a full scale fixed-bed trickling bioreactor. *Int. J. Agric. Biol. Eng.* **2013**, *6*, 69–81.
33. Ihaka, R.; Gentleman, R. R. A language for data analysis and graphics. *J. Comput. Graph. Stat.* **1996**, *5*, 299–314.
34. VDI—Society Energy and Environment. *Fermentation of Organic Materials—Characterisation of the Substrate, Sampling, Collection of Material Data, Fermentation Tests*; Beuth: Berlin, Germany, 2006.

35. Kumanowska, E.; Zielonka, S.; Krümpel, J.; Kress, P.; Oechsner, H. Novel system for demand-oriented biogas production from sugar beet silage effluent in German practice scale biogas plants. *Agric. Eng. Int.* **2020**, *22*, 118–132.
36. Association of German Agricultural Analytic and Research Institutes (Ed.) *Method Book III—The Chemical Analysis of Feedstuffs*, 3rd ed.; VDLUFA-Verlag: Darmstadt, Germany, 2007.
37. Hammer, B.; Frasco, M. *Package ‘Metrics’: Evaluation Metrics for Machine Learning*, R package Metrics version 0.1.4; R Foundation for Statistical Computing: Vienna, Austria, 2018.
38. Scheftelowitz, M.; Thrän, D. Unlocking the Energy Potential of Manure—An Assessment of the Biogas Production Potential at the Farm Level in Germany. *Agriculture* **2016**, *6*, 20. [[CrossRef](#)]
39. Ahlberg-Eliasson, K.; Westerholm, M.; Isaksson, S.; Schnürer, A. Anaerobic Digestion of Animal Manure and Influence of Organic Loading Rate and Temperature on Process Performance, Microbiology, and Methane Emission from Digestates. *Front. Energy Res.* **2021**, *9*, 109566. [[CrossRef](#)]
40. Hahn, H.; Ganagin, W.; Hartmann, K.; Wachendorf, M. Cost analysis of concepts for a demand oriented biogas supply for flexible power generation. *Bioresour. Technol.* **2014**, *170*, 211–220. [[CrossRef](#)]
41. Hahn, H.; Krautkremer, B.; Hartmann, K.; Wachendorf, M. Review of concepts for a demand-driven biogas supply for flexible power generation. *Renew. Sustain. Energy Rev.* **2014**, *29*, 383–393. [[CrossRef](#)]

5. Gesamtdiskussion

5.1 Modellprädiktive Regelung

Der lastflexible Betrieb einer Biogasanlage zur bedarfsorientierten Stromproduktion kann durch eine modellprädiktive Regelung gewährleistet werden. Der Regelkreis umfasst dabei folgende Komponenten:

1. Bereitstellung einer Eingangsgröße, an der sich der Betrieb der Biogasanlage orientieren soll
2. Bereitstellung eines BHKW-Fahrplans
3. Modell zur Simulation der Biogasproduktion
4. Berechnung der Fütterungspläne, Controller

Bisherige, in der Literatur dargestellte, Ansätze nutzen unterschiedliche Methoden zur Umsetzung der genannten Komponenten. Nachfolgend werden die eigenen Untersuchungen und Ergebnisse mit vergleichbaren Modellen aus der Literatur in Kontext gesetzt. Bisher gibt es nur wenige Veröffentlichungen, die einen Vergleich zulassen. Im Wesentlichen sind Grim (2015), Mauky (2016) und Peters et al. (2019) [22,46,47] zu nennen.

Die Eingangsgröße beinhaltet den Sollwert, der durch den justierten Betrieb der Biogasanlage angestrebt wird. In den Modellen von Grim et al. (2015) [22] basiert dieser auf den Energiekosten des schwedischen Spotmarktes Elspot, wobei die stündlichen Daten des Jahres 2013 genutzt wurden. Auch Mauky et al. (2016) [46] nutzt als Referenzszenario die 2013er-Daten der EPEX (European Power Exchange SE) indem die tägliche Auslastung des BHKWs an den hochpreisigen Stunden orientiert wurde. Der Veröffentlichung von Peters et al. (2019) [47] ist zu entnehmen, dass die Eingangsgröße über den historischen Energiebedarf der Stadtwerke Emden des Jahres 2016 abgeleitet wurde. Dabei wurde der notwendige Methanbedarf berechnet, den es zu produzieren gilt, um den Betrieb des BHKWs an den Energiebedarfsdaten ausrichten zu können. In diesem Zusammenhang schlussfolgert Peters et al. (2019) [47], dass die Prognose der Eingangsgröße unbedingt erforderlich ist, um überhaupt eine vorausschauende Fütterungsplanung zur bedarfsgerechten Biogasproduktion gewährleisten zu können. Im Gegensatz zu den bisherigen Veröffentlichungen wird die Eingangsgröße für den lastflexiblen Betrieb der Biogasanlage nicht aus Erfahrungswerten über den Strombedarf oder aus den Börsenstrompreisen abgeleitet, sondern aus dem lokalen, aktuellen Bedarf einer „Modellregion“. Die vorliegenden Forschungsergebnisse der

Publikation 1 umfassen ein Prognosemodell zur Vorhersage des Strombedarfs einer Region über 48 Stunden im Voraus, um diesen zur Bereitstellung eines BHKW-Fahrplans und damit zur Ableitung des erforderlichen Biogasbedarfs und der Fütterungsplanung nutzen zu können. Damit unterscheidet sich die in dieser Arbeit entwickelte modellprädiktive Regelung bereits bei der ersten Komponente grundlegend von bisherigen Modellen. Als Reallabor zur praxisnahen Evaluation des Prognosemodells diente der „Untere Lindenhof“. Der Stromverbrauch der gesamten Forschungsstation umfasst 840'000 kWh pro Jahr, was bei einem angenommenen jährlichen Pro-Kopf-Stromverbrauch von 6'800 kWh (Stand 2021) einem Dorf mit ca. 125 Einwohnern entspricht [49]. Die Strombedarfsprofile des Standortes zeigen typische Schwankungen, sodass in der Nacht ein geringerer und tagsüber ein höherer Stromverbrauch anfällt. Für den September 2022 konnte beispielsweise tagsüber (zwischen 7 und 18 Uhr) ein durchschnittlicher stündlicher Stromverbrauch von 95 kW gemessen werden, in der Nacht (zwischen 19 und 6 Uhr) waren es lediglich 77 kW. Auch die Wochenenden weisen einen niedrigeren Strombedarf als die Tage unter der Woche auf. Die exemplarischen Messwerte des September 2022 bestätigen auch dies, indem an den Wochenenden durchschnittlich 78 kW, an den Wochentagen hingegen 89,5 kW pro Stunde verbraucht wurden. Dieser wechselnde Strombedarf der „Modellregion“ konnte sowohl mit einem TBATS- als auch mit ARIMA-Modellen sehr exakt prognostiziert werden. Die Ergebnisse der Publikation 1 zeigen Resultate von einem Mean Absolute Percentage Error (MAPE) von 13-14 % für den „Unteren Lindenhof“. Zum Vergleich beschreibt Hirsch (2015) [32] einen MAPE von über 80% bei der Vorhersage des Strombedarfs einzelner Haushalte mittels eines ARIMA-Modells. Eine weitere Studie untersuchte Prognosemodelle für die Vorhersage des nationalen Strombedarfs der Türkei, deren Ergebnisse einen MAPE von nur 3 % aufzeigen [50]. Je kleinteiliger entsprechend der Einzugskreis der Verbraucher ist, desto schwieriger wird eine Vorhersage. Damit lässt sich schlussfolgern, dass die Koordination von Stromverbrauch und -produktion innerhalb sinnvoll abgestimmter Systemgrenzen erfolgen sollte, um eine ausreichende Prognosegüte gewährleisten zu können. Eine sinkende Prognosegüte geht immer einher mit einem Anstieg an erforderlichen Gas- oder Stromspeicherkapazitäten, die im Fall einer angestrebten Stromautarkie eines Standortes die Abweichungen zwischen prognostiziertem und tatsächlichem Stromverbrauch kompensieren müssen. Weiterführend könnte neben der Prognose des Strombedarfs auch die Vorhersage des thermischen Energiebedarfs eines Standortes von Interesse sein, da bei der Stromerzeugung über das

BHKW immer nutzbare thermische Energie in einer vergleichbaren Größenordnung erzeugt wird. Empfehlenswert wäre, die Eignung der vorliegend evaluierten Modelle zur Prognose des Strombedarfs, das TBATS sowie angepasste ARIMA-Modelle, zur Vorhersage des Wärmebedarfs zu prüfen. Wie es beispielsweise in Taieb et al. (2016) [51] beschrieben ist, sollte dabei die zusätzliche Berücksichtigung der Außentemperatur als exogene Variable erfolgen, da eine Korrelation dieser beiden Kennwerte naheliegt.

Die zweite Komponente des Regelkreises umfasst die Bereitstellung des BHKW-Fahrplans. Grim et al. (2015) [22] beschreiben eine vordefinierte Stromerzeugungsstrategie, mit der die stufenweise Nutzung der BHKW-Kapazität erfolgt und der Füllstand des Gasspeichers als limitierender Faktor gilt. Die Basis stellen verschiedene Flexibilitäts-Szenarios dar, die im Vergleich mit einer konstanten Fahrweise stehen. In der Veröffentlichung von Mauky et al. (2016) [46] wird in diesem Zusammenhang weiterer Forschungsbedarf empfohlen. Es sollen Modelle entwickelt werden, welche die Gesamtanlage umfassen und damit beispielsweise auch die Dynamiken zwischen Gasspeicher und BHKW beschreiben. Im Zuge dieser Arbeit wurde auf Untersuchungen der Hochschule Reutlingen zur Erstellung eines BHKW-Fahrplans zurückgegriffen, welche im Wesentlichen durch Widmann (2017), Lödige (2015) und Haase et al. (2021) [52–54][52–54] publiziert sind. Dabei basiert die Fahrplanerstellung auf dem heuristischen Ansatz des Monte-Carlo-Verfahrens. Zunächst wird eine vordefinierte Menge an zufälligen Fahrplänen generiert, die lediglich die Information enthalten, ob das BHKW an oder aus ist. Wird ein Fahrplan ausgewählt, der das Einschalten des BHKW vorsieht, wird zudem ein optimaler Modulationsgrad pro Zeitschritt in Abhängigkeit des prognostizierten Strombedarfs berechnet. Die verfügbaren Fahrpläne können weiterhin über Randbedingungen, wie beispielsweise den Füllstand des Gasspeichers, limitiert werden. Aus der erzeugten Anzahl von Fahrplänen wird abschließend derjenige ausgewählt, bei dem die Anforderungen und Randbedingungen bestmöglich erfüllt werden. Hierzu wird ein angepasster Optimierungsalgorithmus verwendet, welcher durch Maier et al. (2020, 2022) [23,24,55] beschrieben ist. Der jeweils resultierende BHKW-Fahrplan stellt auch die Grundlage für die Berechnung des benötigten Biogasbedarfs, der über den elektrischen Wirkungsgrad des BHKWs abgeleitet wird.

Das Modell zur Simulation der aus einer Substratzufuhr zum Fermenter („Fütterung“) resultierenden Biogasproduktion kann als Kernkomponente der modellprädiktiven Regelung

bezeichnet werden und weist in der vorliegenden Arbeit gegenüber bisherigen Entwicklungen einen gänzlich neuartigen Ansatz auf. Die Literatur verzeichnet zwar mannigfaltige Untersuchungen zur Vorhersage der Biogasproduktion, jedoch ist die Zielsetzung meist das Prozessmonitoring einer Biogasanlage oder das Erreichen einer möglichst konstant hohen Biogasproduktion. Mit dem Hintergrund eines Einsatzes zur bedarfsorientierten Biogasproduktion basieren bisher veröffentlichte Modelle durchgehend auf dem ADM1. Die Grundidee des ADM1 ist es, dass auf Basis der Kenntnis der exakten Substratzusammensetzung sowie der physikalisch-chemischen Eigenschaften des Gärsubstrates für jeden Konversionsschritt von der Biomasse zum Biogas deren Kinetik ermittelt werden kann. So ergibt sich ein komplexes Gesamtmodell der Biogasproduktion, dass aufgrund von Informationsdefiziten (u.a. fehlender Messtechnik) kaum mehr für Prognosen an realen Anlagen genutzt werden kann. In der Veröffentlichung von Peters et al. (2019) [47] wird daher als sogenanntes Prozessmodell die modifizierte Version ADM1xp von Wett et al. (2006) [56] verwendet. Mauky et al. [46] nutzen eine Vereinfachung des ADM1, die durch Weinrich et al. (2015) [57] beschrieben ist. Das im Rahmen dieser Arbeit entwickelte Simulationsmodell beruht auf der Zeitreihenanalyse und ist in der Publikation 2 dargestellt. Details werden in dem nachfolgenden Abschnitt 5.1.1 erörtert.

Die letzte Komponente der modellprädiktiven Regelung umfasst das eigentliche Fütterungsmanagement und kann als Controller bezeichnet werden. Die Berechnungsergebnisse der vorgelagerten Modelle fließen in den Controller, sodass Steuerungsbefehle als Output generiert werden können. Die Entwicklungen von Peters et al. (2019) [47] sehen hierfür den Einsatz eines Proportional Integral Controllers (PI) vor. Mauky et al. (2016) [46] beschreibt eine Optimierungsfunktion, die iterativ das Ausgangssignal in Abhängigkeit des Eingangssignals (Sollwert) anpasst. In Publikation 3 werden die entsprechenden Ergebnisse, die im Rahmen dieser Arbeit erzielt wurden, dargelegt. Anders als bisherige Entwicklungen wird eine Art Monte Carlo Algorithmus verwendet, um eine große Anzahl unterschiedlicher Fütterungspläne generieren zu können. Über das Simulationsmodell kann die resultierende Biogasproduktion jedes Fütterungsplanes berechnet und der geeignetste ausgewählt werden. In dem Abschnitt 5.1.2 erfolgt eine detaillierte Diskussion des entwickelten Controllers.

5.1.1 Simulationsmodell Biogasproduktion

5.1.1.1 Vergleich Simulationsmodell mit dem ADM1

Mit der Veröffentlichung des ADM1 durch Batstone et al. (2002) [58] besteht ein Basiskonzept zur Modellierung und Simulation von anaeroben Prozessen. Ursprünglich stammt das Modell aus dem Bereich der Abwasserbehandlung, kann und wird jedoch auch für den Bereich der landwirtschaftlichen Biogaserzeugung genutzt. Aufgrund einiger unterschiedlicher Anforderungen besteht diesbezüglich aber die Notwendigkeit der Modellanpassung [59]. Dabei seien drei grundlegende Einstellungen genannt, die mit der Simulation des anaeroben Prozesses der Biogasanlage schwer vereinbar sind:

1) Zum einen basiert das ADM1 auf der Charakterisierung der Einsatzsubstrate über den chemischen Sauerstoffbedarf (CSB) als zentrale Einheit. Dieser Wert kann nur für Substrate mit einem geringen Anteil an organischer Fracht (z.B. Abwässer) mit einer hinreichenden Genauigkeit ermittelt werden und ist zur Beschreibung von Einsatzstoffen wie nachwachsenden Rohstoffen oder Festmist gänzlich ungeeignet [59]. Weinrich et al. (2020) [60] beschreiben dazu, dass der CSB keine Aussage über die anaerobe Abbaubarkeit dieser Substrate erlaubt und hinsichtlich der tatsächlich fermentierbaren Substratbestandteile korrigiert werden muss.

2) Des Weiteren ist das ADM1 auf die gleichbleibende Zusammensetzung nur eines Substrates im Zufluss ausgelegt. In der Biogasanlage wird jedoch immer ein inhomogener Mix an verschiedenen Substraten vergoren. Dementsprechend müssen zentrale Änderungen der Initialparameter des Modells erfolgen.

3) Weiterhin stellt die Verfügbarkeit der umfangreichen Datensätze, die zur Nutzung des ADM1 erforderlich sind, eine Herausforderung dar. Zu folgenden Kernprozessen müssen für jede Biogasanlage individuelle Parameter ermittelt werden [59]:

- Stoffumsetzungen aus Desintegration, Hydrolyse, Acidogenese, Acetogenese, und Methanogenese
- Bakterienwachstum und Substrataufnahme je nach Substratverfügbarkeit für die jeweilige Organismengruppe
- Prozessinhibition aufgrund von pH-Wert (alle Gruppen), Wasserstoffkonzentration (acetogene Bakterien) und der Konzentration von freiem Ammoniak (acetoklastische methanogene Bakterien)

- Physikalisch-chemische Prozesse: Säure-Basen-Reaktionen, Flüssigkeits-Gas-Austausch

Alle Modellparameter müssen individuell für jeden zu simulierenden anaeroben Prozess ermittelt werden. Demgegenüber steht, dass Biogasanlagen nur sehr rudimentär mit Mess-, Regel- und Steuerungstechnik ausgestattet sind, wie in Gaida et al. (2017) [48] beschrieben. Auch in Hülsemann (2022) [61] wird die Problematik diskutiert, dass Betreiber landwirtschaftlicher Biogasanlagen oftmals nicht ausreichend in Messtechnik und deren Kalibrierung investieren, sodass beispielsweise nur die Gesamtmenge der dosierten Substratmischungen und nicht die der individuellen Substrate ermittelt werden kann.

Um das ADM1 dennoch zur Simulation der Biogasproduktion nutzen zu können, gibt es Entwicklungen zur Vereinfachung des Modells, wie primär durch Publikationen von Weinrich et al. (2017, 2021, 2017, 2015) [18,57,62,63] beschrieben. Dabei wird das CSB-basierte ADM1 zunächst anhand charakteristischer Referenzsubstrate in ein massebasiertes (oTS, organischer Trockensubstanzgehalt) Modell überführt. Weiter werden die 31 kinetischen Modellparameter und Inhibierungskonstanten auf nur noch 4 Reaktionskonstanten erster Ordnung reduziert. Von 21 physikochemischen Konstanten werden nur noch 14 zur Beschreibung der Dissoziationsgleichgewichte verwendet. Die Anzahl der Prozesse respektive der Zustandsgleichungen reduziert sich von 19 auf nur noch 4 und anstatt 34 Zustandsgrößen werden nur noch 10 benötigt [62]. Bestehen bleibt jedoch die Herausforderung der Datenbeschaffung, vorrangig zu den eingesetzten Substraten. Wie in Wett und Weinrich et al. (2006, 2015) [56,63] dokumentiert, werden konkrete kinetische Substrateigenschaften über eine Fraktionierung in Fette, Proteine und Kohlenhydrate ermittelt. Diesbezüglich müssen sowohl die Mengenverhältnisse der in die Biogasanlage eingetragenen Substrate permanent erfasst als auch deren konkrete Zusammensetzung bekannt sein. Nahezu keiner dieser Parameter wird heute auf großtechnischen Biogasanlagen gemessen, weshalb die Charakterisierung der Substrate über die Weender Futtermittelanalyse, wie in Peters et al. (2019) [47] beschrieben, erfolgt. Diese Analyse der Substrate wird in Laboruntersuchungen (nasschemisch oder über Nahinfrarot-Spektroskopie-Verfahren, wenn eine Kalibration vorliegt) oder als Ableitung aus Verdauungsversuchen bei Wiederkäuern durchgeführt [63]. Dienlich wäre in diesem Zusammenhang die Verwendung nur eines Substrates, welches sich in der Zusammensetzung als sehr konsistent erweist, wie es auch in der Abwasserbehandlung

der Fall ist [48]. Diese Voraussetzung ist jedoch auf einer großtechnischen Biogasanlage nie gegeben. Bei Veränderungen in der Substratzufuhr muss entsprechend jedes Mal eine neue Ermittlung und Justierung der Modellparameter erfolgen. Zusammenfassend kann festgestellt werden, dass das ADM1, auch in vereinfachter Form, bisher wenig praxistauglich und kaum adaptierbar ist.

Das in der vorliegenden Arbeit entwickelte Modell (Publikation 2) verfolgt daher einen gänzlich anderen Ansatz der Biogassimulation, der auf der Zeitreihenanalyse basiert. Über ein Regressionsmodell kann aus historischen Daten der Zusammenhang zwischen Substratzugabe und zeitlich versetzter Biogasproduktion mathematisch beschrieben und für die Simulation zukünftiger Biogasproduktionen genutzt werden. Die Modellentwicklung zielt auf eine praxistaugliche Verwendung ab, die im Zuge der Publikation 3 dargelegt wird. Es sind im Wesentlichen zwei Vorteile gegenüber den bisherigen Modellentwicklungen zu nennen: 1) Die benötigten Modellparameter umfassen lediglich Daten zur Biogasproduktion und zu der zugeführten Substratmenge. Überdies müssen die Substrate nicht in ihrer qualitativen Zusammensetzung beschrieben werden; es wird lediglich eine Angabe zur Menge der eingesetzten Feststoffe, unabhängig ihrer Zusammensetzung, benötigt. Alle diese Parameter können über standardisierte Messtechnik erfasst werden, welche üblicherweise auf den meisten Biogasanlagen bereits implementiert ist. 2) Das Modell ist „selbstlernend“ und adaptierbar und kann sich damit auf Veränderungen der Betriebsbedingungen, verschiedene Substrate oder auch gänzlich andere Biogasanlagen einstellen, ohne dass umfangreiche Justierungen am Modell vorgenommen werden müssen.

Die Qualität der Simulationsergebnisse des entwickelten Modells gegenüber dem Modell basierend auf dem ADM1, welches im Zuge der Publikation von Mauky et al. (2016) [46] Verwendung findet, steht wie folgt im Vergleich:

Das im Zuge dieser Arbeit entwickelte Simulationsmodell wurde anhand der Qualitätsparameter MAPE, sowie dem Root Mean Squared Error (RMSE) und dem Mean Absolute Error (MAE) bewertet. Dabei wurde in einer extensiven Evaluation über 366 Simulationen über jeweils 48 Stunden ein durchschnittlicher MAPE von unter 20 % erreicht. Die RMSE- und MAE-Werte lagen durchschnittlich bei unter $10 \text{ m}^3 \text{ h}^{-1}$ bei einer mittleren Biogasproduktion zwischen 60 und $70 \text{ m}^3 \text{ h}^{-1}$. Die Simulationsergebnisse von Mauky et al. (2016) [46] wurden anhand der relativen Standardabweichung der Fehler der Simulation

bewertet (σ_{est}). Die tageweise Betrachtung zeigt bei einer hohen Korrelation einen σ_{est} -Wert von unter 10 %, bei einem Abfall der Raumbelastung und einer sinkenden Biogasproduktion reduziert sich tendenziell die Qualität der Simulationsergebnisse auf σ_{est} -Werte von 15 bis 17 %. Bei einem Anstieg der Raumbelastung verschlechtert sich der σ_{est} -Wert nochmal merklich auf bis über 20 %. Ein abschließender, detaillierter Vergleich der Ergebnisse beider Simulationsmodelle kann aufgrund der unterschiedlichen Evaluationen hinsichtlich der ermittelten Qualitätsparameter, des Prognosehorizontes, der Anzahl an durchgeführten Simulationen etc. nicht vorgenommen werden. Um die Ergebnisse beider Simulationsmodelle dennoch einordnen zu können, wurde der σ_{est} -Wert auch für die Ergebnisse des im Zuge dieser Arbeit entwickelten Simulationsmodells berechnet. Im Durchschnitt über alle simulierten Werte der 366 durchgeführten Simulationen, dargelegt in Publikation 2, konnte ein insgesamt sehr niedriger σ_{est} -Wert von 12,4 % ermittelt werden. Unter Vorbehalt der genannten Einschränkungen bei der Vergleichbarkeit kann schlussfolgernd angenommen werden, dass das entwickelte Simulationsmodell durchschnittlich leicht bessere Ergebnisse als das Simulationsmodell von Mauky et al. (2016) [46] erzielt.

5.1.1.2 Kritische Diskussion des Simulationsmodells

Das Simulationsmodell unterscheidet sich grundlegend von den bisherigen ADM1-basierten Methoden, wie bereits im vorherigen Abschnitt 5.1.1.1 dargelegt wurde. Es hat sich gezeigt, dass die Zeitreihenanalyse als Basis zur Simulation des Biogasbedarfs einige Vorteile für sich verbuchen kann. In erster Linie erweist sich die Methode als besonders simpel und funktional, sodass die Berechnungen nachvollziehbar und reproduzierbar bleiben. Damit wird das Modell auch adaptierbar und passt sich ohne Justierungen auf unterschiedliche Betriebszustände an. Letzteres lässt sich vermutlich auch mit der Methode der künstlichen neuronalen Netze erreichen, die in der Publikation von Peters et al. (2019) [47] empfohlen wird. Hier müssen jedoch wiederum erhebliche Abstriche hinsichtlich der Anwendbarkeit gemacht werden, da eine große Anzahl an umfangreichen Trainingsdaten erforderlich ist, um den Vorteil eines selbstlernenden Modells zu erreichen [64,65].

Was sich als vorteilhaft des im Zuge dieser Arbeit entwickelten Modells gegenüber der definierten Zielsetzung zeigt, kann sich in anderen Anwendungsfällen als nachteilig erweisen. Die sogenannten „Black-Box-Modelle“ funktionieren ohne jegliches Wissen zu Prozesszuständen oder physikalischen Abhängigkeiten des Fermentationsprozesses [66]. Damit lässt sich die Biogasproduktion mit einem Minimum an erfassten Daten simulieren,

jedoch können weder Prozessstörungen frühzeitig erkannt, noch Gründe für eine ungewöhnlich niedrige Biogasproduktion detektiert werden. Damit eignet sich die verwendete Methode nicht für ein umfangreiches Prozessmonitoring oder zur Effizienzsteigerung der Biogasanlage.

Es stellt sich jedoch die Frage, ob sich das Simulationsmodell zur Ermittlung der Gasbildungskinetik bestimmter Substrate oder Substratmischungen verwenden ließe. In der Publikation 2 sind die berechneten Modell-Koeffizienten als Indikator für die zeitabhängige Entwicklung der Biogaserzeugung in Abhängigkeit von der Feststoffzufuhr grafisch dargestellt. Daraus lässt sich der zeitliche Verlauf der Biogasproduktion aus der aktuellen Substratverwendung ableiten. Im Zuge der Berechnung einer durchschnittlichen Biogasproduktion pro kg eingesetzter Frischmasse ergeben sich jedoch unplausibel niedrige Werte. Erklären lässt sich dies durch den y-Achsenabschnitt, definiert als Parameter „Intercept“, der eine Restmenge des produzierten Biogases enthält und damit quasi die konstant bleibende Grundlast der Biogasproduktion, die bei einer kontinuierlichen Fütterung des Fermenters auftritt, darstellt. Zur konkreten Ermittlung von Gasbildungskinetiken bestimmter Substrate werden daher weitergehende Versuche zur Verwendung eines Regressionsmodells ohne den Parameter „Intercept“ vorgeschlagen. Alternativ kann auch der Ersatz des „Intercepts“ durch eine sinnvolle „Dummy-Variable“, die eine gleichbleibende Grundlast der Biogasproduktion beschreibt, untersucht werden.

Im Zuge der empfohlenen weiterführenden Untersuchungen zu dem Modellparameter „Intercept“, kann auch erneut die Berücksichtigung flüssiger Inputsubstrate als zusätzlicher Regressor bewertet werden. Die Ergebnisse der Publikation 2 beweisen, dass die Integration dieses zusätzlichen Regressors unter den gegebenen Bedingungen nicht sinnvoll ist. Die nahezu kontinuierliche Fütterung und Ausgasung der Gülle führte zu keinen signifikanten und damit darstellbaren Ausschlägen in der Biogasproduktion. Es kann davon ausgegangen werden, dass die aus der Güllezufuhr resultierte Biogasproduktion nur in dem „Intercept“ abgebildet wird. Daher stellt sich die Frage, wie sich die Modellparameter bei einer Berechnung ohne „Intercept“ verändern und interpretieren lassen. Weiterhin wäre diese Untersuchung dahingehend interessant, dass das Simulationsmodell auf unterschiedlichste Biogasanlagen adaptierbar sein soll und somit auch Anlagen mit gänzlich unterschiedlichem Fütterungsverhältnissen von flüssigen gegenüber festen Substraten abgedeckt werden sollen.

Die Anwendbarkeit des Simulationsmodells auf unterschiedlichen Biogasanlagen betreffend, kann auch die zeitliche Verzögerung mit der die Biogasproduktion bei einer Substratzufuhr einsetzt, die durch die Anzahl der „Lags“ definiert wird, nochmals eingehender geprüft werden. In der Publikation 2 wurde erörtert, dass eine Anzahl von 48 „Lags“, entsprechend 48 Stunden, für beide untersuchten Systeme die besten Ergebnisse liefert. Es kann damit vermutet werden, dass mit diesen Modelleinstellungen bei dem Großteil der landwirtschaftlichen Biogasanlagen ähnlich gute Ergebnisse erzielt werden können. Grund dieser Annahmen ist, dass die Prozessbedingungen und die Auswahl der Substrate repräsentativ für einen typischen Biogasbetrieb sind. Inwieweit sich jedoch eine optimale Anzahl der „Lags“ bei einem thermophilen Betrieb, bei dem Einsatz von schwer vergärbaren Substraten wie beispielsweise Festmist bzw. Stroh oder bei inhomogenen Substraten wie organischen Abfällen und Grüngut verhält, ist noch nicht geprüft.

5.1.2 Berechnung der Fütterungspläne, Controller

Über den Controller schließt sich der Regelkreis der modellprädiktiven Regelung zur bedarfsorientierten Stromproduktion. Die Regelung der Substratzufuhr in anaeroben Fermentationsprozessen wurde in einem Review von Gaida et al. (2017) [48] umfangreich evaluiert. Die Zielsetzung der meisten Controller umfasst jedoch beispielsweise die Maximierung der Biogasproduktion oder auch Prozessstabilität, indem Grenzwerte zu flüchtigen Fettsäuren oder gelöstem Wasserstoff kontrolliert werden. Die ersten im Kontext der anaeroben Fermentation angewendeten Kontrollmethoden waren einfache Ein-/Aus-Steuerungen, gefolgt von PI-Reglern [67]. Sollen mehrere, möglicherweise konfliktbehaftete Sollwerte gleichzeitig geregelt werden, kommen sogenannte Expertensysteme zum Einsatz, wie z.B. die Fuzzy-logic-Regelung [68]. Um das gesamte Prozessverhalten modellieren zu können, finden oftmals neuronale Netze Verwendung [69].

Peters et al. (2019) [47] nutzt konkret im Zuge eines lastflexiblen Biogasanlagenbetriebes zur bedarfsorientierten Stromproduktion einen PI-Regler. Dieser liest den Sollwert in Form des Methanbedarfs ein und vergleicht diesen mit der berechneten Methanproduktion des Prozessmodells (ADM1xp). Aufgrund der errechneten Differenz werden die Fütterungsmengen kalkuliert. Dadurch gelingt es, lang- und mittelfristige Schwankungen im Bedarf mittels PI-Regler zu decken, jedoch können kurzfristige Schwankungen nicht gewährleistet werden. Insgesamt wurde festgestellt, dass die Wahl des PI-Reglers nicht gut geeignet ist. Gründe dafür sind zum einen, dass es sich um einen linearen

Reglungsmechanismus handelt, die Biogasproduktion aber nicht linear verläuft. Zum anderen zeichnet sich der PI-Regler durch Reaktivität aus, indem er schnell auf Abweichungen reagiert. Was oftmals als Vorteil zu werten ist, ist in diesem Fall nachteilig, da die Fermentation ein insgesamt träger Prozess ist. Aus diesem Grund werden Expertensysteme empfohlen, wie beispielsweise neuronale Netze. Mauky et al. (2016) [46] nutzen in ihrer modellprädiktiven Regelung hingegen eine Optimierungsfunktion zur iterativen Anpassung des Ausgangssignals um eine bestmögliche Übereinstimmung mit dem Sollwert zu erreichen. Diese ist grundsätzlich gut geeignet, limitierend in dem Gesamtmodell erweist sich eher das Prozessmodell (ADM1) aus den bereits beschriebenen Gründen (vgl. Abschnitt 5.1.1).

Für die Berechnung der Fütterungspläne wurde im Zuge der vorliegenden Arbeit zunächst eine Umkehrung des Biogassimulationsmodells (Publikation 2) in Betracht gezogen. Aufgrund der in dem Modell berücksichtigten Verzögerung in der Biogasproduktion (Lags) war eine Berechnung der Unbekannten durch Rücksubstitution jedoch nicht zielführend. Auch eine iterative Annäherung, vergleichbar mit der Methodik von Mauky et al. (2016) [46], wurde geprüft, jedoch aufgrund dessen, dass sich die Methode eines Monte-Carlo-Ansatzes als funktionaler erwies, nicht weiter verfolgt. Im Zuge der Publikation 3 ist diese gewählte Methode des Monte-Carlo-Ansatzes veröffentlicht, und sie funktioniert gänzlich unterschiedlich zu den beschriebenen Methoden von Mauky (2016) und Peters et al. (2019) [46,47]. Ein Monte-Carlo-Algorithmus arbeitet standardmäßig ergebnisoffen mit Zufallswerten. Das vorliegende Modell berücksichtigt jedoch einige Randbedingungen, um zum einen technische Limitierungen der Anlagen einzuhalten und zum anderen die Chancen auf einen passenden Fütterungsplan zu erhöhen. Ersteres lässt schlussfolgern, dass einige Randbedingungen anlagenspezifisch sind und daher im Fall einer Adaption des Modells neu justiert werden müssen. Dazu gehört die Portionierung, also die vordefinierte Menge an Substraten, die pro vorgesehene Fütterung eingesetzt wird. Diese muss auf die technische Ausstattung der Biogasanlage (Feststoffdosierer, Eintragssysteme, Rührtechnik, Verweilzeiten, Raumbelastungen etc.) abgestimmt werden. Inwieweit sich die Einstellungen auf anderen Biogasanlagen gegenüber denen in der Publikation 3 veröffentlichten ändern müssen, sollte in weiteren praktischen Versuchen eruiert werden.

Die Auswahl eines geeigneten Fütterungsplanes erfolgt durch den Vergleich der simulierten Biogasproduktionen mit dem Biogasbedarfsprofil (Sollwert). Dabei wird der

Vergleich anhand des Qualitätsparameters Symmetric Mean Absolute Percentage Error (SMAPE) vorgenommen, dargestellt in Formel 1 [70].

$$SMAPE = \frac{|D_t^s - z_t^s|}{(|D_t^s| + |z_t^s|)}$$

- z_t^s simulierte Biogasproduktion in m^3 , mit dem Index t für Zeit und s steht für Serie
- D_t^s Biogasbedarf in m^3 , mit dem Index t für Zeit und s steht für Serie

Die Auswahl für diesen Qualitätsparameter lässt sich dadurch begründen, dass der SMAPE auch Werte liefert, sollte die Simulation oder der Bedarf einen Wert nahe der Null annehmen. Ein wesentlicher Nachteil bei der Nutzung des SMAPE ergibt sich durch eine Asymmetrie, die durch den Nenner der Formel (vgl. Formel 1) verursacht wird. Ist der simulierte Wert um eine definierte Differenz größer als der des Bedarfs, resultiert ein geringerer SMAPE-Wert, als wenn die gleiche Differenz durch einen kleineren simulierten Wert gegenüber dem Bedarfswert zustande kommt. Damit müssten im Umkehrschluss bevorzugt Fütterungspläne ausgewählt werden, die tendenziell eine höhere Biogasproduktion als gewünscht zur Folge haben. In Anbetracht der Ergebnisse der Publikation 3 konnte für den gesamten Versuchszeitraum ermittelt werden, dass die Differenz zwischen der Summe an Biogasbedarfs- und Simulationswerten einen Wert von $-1578 m^3$ ergibt. Dies bestätigt die Vermutung, dass die simulierten Werte tendenziell größer sind. Schlussfolgernd könnten Untersuchungen zu alternativen Qualitätsparametern zur Auswahl des geeigneten Fütterungsplanes sinnvoll sein.

5.2 Schlussfolgerungen und Ausblick

Die im Rahmen dieser Arbeit präsentierten Ergebnisse zeigen die experimentelle Entwicklung einer modellprädiktiven Regelung für Biogasanlagen um eine bedarfsorientierte Stromproduktion zu ermöglichen. Folgende Schlussfolgerungen lassen sich aus den erzielten Ergebnissen ableiten:

- Es wurden Prognosemodelle zur Vorhersage des Strombedarfs am Beispiel des Reallabors „Unterer Lindenhof“ evaluiert und praktisch getestet. Damit konnte erstmalig ein Modell zur konkreten Vorhersage des Sollwertes, an dem sich der Betrieb

der Biogasanlage orientieren soll, in eine modellprädiktive Regelung implementiert werden.

- Die Prognose sollte in sinnvoll abgestimmten Systemgrenzen erfolgen, damit der Prognosefehler begrenzt bleibt. Das zugrundeliegende Reallabor kann mit seinem Strombedarf als Minimum gewertet werden.
- Weiterhin wurde ein gänzlich neuer Ansatz zur Simulation der Biogasproduktion gewählt, womit eine Alternative zu den bisherigen sehr komplexen ADM1-Modellen geschaffen werden konnte.
- Alle benötigten Modellparameter für diesen neuen Ansatz sind auf den meisten Biogasanlagen über standardisierte Messtechnik ermittelbar, womit erstmals ein leicht in der Praxis anwendbares und auf verschiedene Biogasanlagen adaptierbares Modell aufgezeigt werden kann.
- Der erzielte MAPE liegt bei 14-18 %, womit die Qualität der Simulationsergebnisse in einem guten Bereich anzuordnen ist.
- Der entwickelte Controller zur Fütterungsplanung basiert auf einer Monte-Carlo-Methode, die ebenfalls in diesem Kontext neuartig ist. Es sind wenige anlagenspezifische Randbedingungen implementiert, die bei einer Adaption ggf. angepasst werden müssen.
- Die modellprädiktive Regelung wurde als Gesamtmodell in einem praktischen Versuch über 36 Tage auf der Forschungsbiogasanlage am Unteren Lindenhof implementiert und getestet. Damit konnte der hohe Grad an Praxistauglichkeit sowie eine gute Qualität der Ergebnisse nachgewiesen werden. Bei dem Vergleich der Werte des Biogasbedarfs mit denen der –produktion zeigte sich ein durchschnittlicher MAPE von unter 20 %.

Die grundsätzliche Anwendbarkeit der modellprädiktiven Regelung in großtechnischen Biogasanlagen war eine der prioritären Zielsetzungen der Entwicklungen und konnte erreicht werden. Es empfiehlt sich jedoch, die Adaption der Modelle noch umfangreicher zu evaluieren. Dafür sollten diese auf weiteren Biogasanlagen mit anderen Betriebsbedingungen, insbesondere hinsichtlich der eingesetzten Substrate, getestet werden. Eventuell kann die Einbindung einer Gasqualitätsmessung zu weitergehender Automatisierung bei der fixen Portionierung der Substrate verhelfen, da Prozessstörungen erkennbar werden. Weiterhin wäre die Implementierung des Gasspeichermanagements, welches zum Ausgleich von

Ungenauigkeiten der modellprädiktiven Regelung sowie bei sehr kurzfristigen Schwankungen in der Stromnachfrage zwingend erforderlich ist, eine sinnvolle Weiterentwicklung des Modells.

Des Weiteren stellt sich die Frage nach dem aktuellen Bedarf einer modellprädiktiven Regelung zum lastflexiblen Betrieb einer Biogasanlage. Die Vorteile einer bedarfsgerechten Stromproduktion im Zuge des Ausbaus der Erneuerbaren Energien und zukünftigen Energieversorgungsstrukturen sind bekannt und in Abschnitt 1 detailliert dargelegt. Die ökonomische Seite wurde im Zuge dieser Arbeit jedoch bisher nicht beleuchtet. Insbesondere für Biogasanlagen die bis dato auf Basis von nachwachsenden Rohstoffen und nach den Vorgaben des EEG 2004 betrieben werden, ist derzeit fraglich, welche alternativen Konzepte einen wirtschaftlichen Weiterbetrieb erlauben. Neue Vermarktungsformen, in denen eine modellprädiktive Regelung zur bedarfsorientierten Stromproduktion sinnvoll einsetzbar sein könnte, sind beispielsweise der Peer-to-Peer-Handel oder Energie-Communities. Auch langfristige Stromlieferverträge zu festgelegten Konditionen in Form von Power Purchase Agreements (PPA) könnten interessant sein. Grundsätzlich ist betreffend dieser neuen Vermarktungsformen jedoch festzustellen, dass noch erhebliches Potential an Weiterentwicklung, Etablierung und vor allem Akzeptanz der potentiellen Nutzer besteht [71]. Auch rechtlich lassen sich Märkte für regionale Flexibilitätsdienstleistungen derzeit noch nicht gänzlich einordnen. Genauso unklar ist momentan die politische Unterstützung hinsichtlich möglicher Förderungen für diese Form der bedarfsorientierten Stromproduktion. Einhergehend bedarf es vor allem der Akzeptanz und einem gewissen Grad an Überzeugung und Motivation seitens der Betreiber der Biogasanlagen, diese neue Ausrichtung des Betriebes mitzutragen.

Für eine erfolgreiche kommerzielle Nutzung des im Rahmen dieser Arbeit entwickelten Modells müssen entsprechend noch Rahmenbedingungen geschaffen werden, die eine ökonomisch sinnvolle Nutzung versprechen. Weitere Schritte könnten in diesem Zusammenhang bedeuten, dass der Sollwert in Form des prognostizierten Strombedarfs einer Region zunächst durch einen Sollwert, der sich am Preissignal des Strommarktes orientiert, ersetzt wird. Dieser kann beispielsweise durch Stromhändler oder Direktvermarkter vorgegeben werden. Des Weiteren sollte geprüft werden, welcher Anteil der Bestandsanlagen in Deutschland für eine Nutzung der modellprädiktiven Regelung zur bedarfsorientierten

Stromproduktion unter Berücksichtigung aller technischer und ökonomischer Kriterien in Frage kommt, um die erwarteten großen Potentiale der vorliegenden Entwicklungen greifbarer zu machen.

6. Zusammenfassung

Die Transformation des Energiesystems macht aufgrund zunehmend dezentraler, fluktuierender Stromeinspeisungen durch Wind- und PV-Anlagen, regelbare Stromproduzenten dringend erforderlich. Biogasanlagen können einen substanziellen Beitrag leisten, indem der Anlagenbetrieb flexibilisiert und somit bedarfsgerecht Strom bereitgestellt wird. Durch technische Anpassungen der Anlage, wie beispielsweise dem Ausbau der Gasspeicherkapazitäten und der BHKW-Leistung, lassen sich kurzfristige Schwankungen ausgleichen. Um das Stromerzeugungspotential über längere Zeiträume verlagern zu können, ist jedoch eine angepasste Fütterungsstrategie unabdingbar.

Die Steuerung der Biogasproduktion birgt in der praktischen Umsetzung einige Herausforderungen. Einerseits ist die Konversion von Biomasse in Biogas ein komplexer Vorgang und zudem individuell für jede Biogasanlage zu betrachten. Bisher entwickelte Modelle nutzen daher Parameter zu sämtlichen charakteristischen Prozessphasen und Einflussgrößen, um die anaerobe Fermentation modellieren zu können. Demgegenüber steht die oftmals rudimentäre Ausstattung der Biogasanlagen mit Messtechnik, sodass entsprechende Parameter nicht zur Verfügung stehen.

Im Rahmen dieser Arbeit wurde eine modellbasierte prädiktive Regelung des Biogasanlagenbetriebes entwickelt, die eine dem Bedarf angepasste Stromproduktion ermöglicht. Dabei wurde der Anspruch gefasst, besonders praxistaugliche Modelle zu entwickeln um erstmals einen erfolgreichen Einsatz auf nahezu allen Biogasanlagen mit keinen oder nur wenigen Anpassungen an der vorhandenen Messtechnik zu erlauben.

Alle Untersuchungen, die dieser Arbeit zugrunde liegen, wurden auf Basis eines Reallabors, dem „Unterer Lindenhof“, durchgeführt. Dieses umfasst sowohl eine Praxisbiogasanlage als auch einen Energieverbrauch, der einem Dorf mit ca. 125 Einwohnern entspricht. In einem ersten Schritt wurden Prognosemodelle evaluiert, die den Strombedarf des Reallabors über 48 Stunden im Voraus vorhersagen sollen. Dabei wurden vier Modelle aus dem Bereich der Zeitreihenanalyse untersucht, ein TBATS und drei unterschiedliche ARIMA-Modelle. Über eine Evaluation von jeweils 366 Prognosen zeigten alle vier Modelle mit durchschnittlichen MAPE-Werten von 13-16 % ausreichend gute Resultate um einen Sollwert zur Orientierung des Biogasanlagenbetriebes zu liefern. Zusätzliche Untersuchungen ergaben zudem, dass die Prognose auch über einen Zeitraum von bis zu 14 Tagen erfolgen kann, ohne

stärke Einbußen hinsichtlich der Prognosequalität. In einem weiteren Schritt wurde ein Modell zur Simulation der Biogasproduktion entwickelt. Dieses basiert ebenfalls auf der Zeitreihenanalyse, konkret auf einem Regressionsmodell. Damit unterscheidet es sich maßgeblich von bisherigen Entwicklungen in diesem Bereich, die in den meisten Fällen auf dem komplexen ADM1 beruhen. Sehr vorteilhaft erweist sich, dass das entwickelte Simulationsmodell lediglich historische Daten der letzten vier Wochen von der Biogasproduktion und der dosierten Menge an festen Substraten, unabhängig ihrer Zusammensetzung, als Inputparameter benötigt. Die Simulation der Biogasproduktion über 48 Stunden im Voraus erfolgt basierend auf Korrelationen, die die beiden Datensätze aufweisen. Eine Evaluation des Modells über 366 Simulationen ergab einen durchschnittlichen MAPE von 14-18 %. Dabei wurden die Daten von beiden Fermentern der Praxisbiogasanlage genutzt, die als eigenständige Systeme betrachtet werden können und damit die Adaptierbarkeit des Modells verdeutlichten. In einem dritten Schritt wurde die Fütterungsplanung zur bedarfsorientierten Biogasproduktion entwickelt. Für jeweils 48 Stunden im Voraus wurden 1500 randomisierte Fütterungspläne berechnet. Dabei wurden einige wenige Limitierungen vorgenommen, wie die maximale Substratmenge, die technisch in der Praxisbiogasanlage umsetzbar ist. Die aus den Fütterungsplänen voraussichtlich resultierende Biogasmenge konnte mittels des Simulationsmodells berechnet werden. Über einen Abgleich mit dem gewünschten Biogasbedarfsprofil konnte die Simulation mit den geringsten Abweichungen ermittelt und der zugehörige Fütterungsplan ausgewählt und umgesetzt werden. Die gesamte modellbasierte prädiktive Regelung wurde in einem praktischen Versuch im Reallabor „Unterer Lindenhof“ eingesetzt und eingehend geprüft. Über einen Zeitraum von 36 Tagen konnte ein durchschnittlicher MAPE von unter 20 % im Abgleich von der realen Biogasproduktion zu dem gewünschten Biogasbedarf erreicht werden. Dabei wurde in dem Testzeitraum der Biogasbedarf von dem prognostizierten Strombedarf des Reallabors abgeleitet.

Die Untersuchungen der vorliegenden Arbeit zeigen, dass die entwickelte modellbasierte prädiktive Regelung eine bedarfsgerechte Stromproduktion auf einer großtechnischen Biogasanlage ermöglicht und aufgrund der erstmals sehr praxistauglichen Modelle eine Adaption auf nahezu jede Biogasanlage erlaubt.

7. Summary

The transformation of the energy system requires controllable producers due to increasingly decentralised, fluctuating electricity generation from wind turbines and photovoltaics. Biogas plants can make a substantial contribution here by making plant operation more flexible and thus providing electricity as needed. Technical adjustments, such as the expansion of gas storage capacities and CHP output, can compensate for short-term fluctuations. However, in order to be able to shift the potential of electricity generation over longer periods of time, an adapted feed-in strategy is essential.

The control of biogas production poses several challenges in practical implementation. First, the conversion of biomass into biogas is a complex process and must be considered individually for each biogas plant. Models developed so far use parameters for all characteristic process phases and influencing variables in order to be able to model anaerobic digestion. In contrast, biogas plants are often only rudimentarily equipped with measurement technology, so that corresponding parameters are not available.

In this work, a model-predictive control of biogas plant operation was developed to enable demand-driven electricity generation. The aim was to develop models that are particularly well suited for practical use. Thus, for the first time, a successful application on almost all biogas plants could be possible without or with only minor adaptations to the existing measurement technology.

All studies carried out in this thesis are based on a real-world laboratory, the "Unterer Lindenhof". This includes a practical biogas plant as well as an electrical consumption corresponding to that of a village with about 125 inhabitants. In a first step, forecasting models were evaluated to predict the electricity demand of the real-world laboratory over 48 hours in advance. Four models from the field of time series analysis were examined, one TBATS and three different ARIMA models. In an evaluation of 366 forecasts each, all four models performed sufficiently well to provide a set point for biogas plant operation, with average MAPE values of 13-16 %. Further investigations showed that forecasts can also be carried out over a period of up to 14 days without significant losses in forecast quality. In a further step, a model was developed to simulate biogas production. This is also based on time series analysis, or more precisely on a regression model. Thus, it differs significantly from previous developments in this field, which are mostly based on the complex ADM1. It turns out to be

very advantageous that the developed simulation model uses as input parameters only historical data of the last four weeks of biogas production and the amount of solid substrates fed in, without considering their composition. The simulation of biogas production over 48 hours in advance is based on correlations resulting from these two data sets. An evaluation of the model over 366 simulations resulted in an average MAPE of 14-18 %. Data from both digesters of the biogas plant were used, which can be considered as independent systems, demonstrating the adaptability of the model. In a third step, the feeding schedule was developed for demand-based biogas production. For each 48 hours in advance, 1500 randomised feeding schedules were calculated. Some constraints were imposed, such as the maximum amount of substrate that is technically possible in the biogas plant. The biogas production expected from the feeding schedules could be calculated using the simulation model. By comparing the simulation with the desired biogas demand profile, the simulation with the least deviations could be determined and the appropriate feeding plan selected and implemented. The entire model predictive control system was used and thoroughly tested in a field trial at the real-world laboratory "Unterer Lindenhof". Over a period of 36 days, an average MAPE of less than 20 % was achieved in comparison between the real biogas production and the desired biogas demand. During the test period, the biogas demand was derived from the predicted electricity demand of the real-world laboratory.

The investigations carried out show that the model-predictive control system developed enables demand-oriented electricity generation on full-scale and that, due to the models being very close to practice for the first time, adaptation to almost all biogas plants is possible.

Referenzen

- [1] T. Bruckner, I. A. Bashmakov, Y. Mulugetta, H. Chum, A. de la Vega Navarro, J. Edmonds, A. Faaij, B. Fungtammasan, A. Garg, Mitigation of Climate Change. Contribution of Working Group III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change, Energy Systems (2014).
- [2] acatech/Leopoldina/Akademienunion, acatech – Deutsche Akademie der Technikwissenschaften e. V., Nationale Akademie der Wissenschaften Leopoldina, Union der deutschen Akademien der Wissenschaften e. V., Welche Auswirkungen hat der Ukrainekrieg auf die Energiepreise und Versorgungssicherheit in Europa?, Akademieprojekt "Energiesysteme der Zukunft" (ESYS) (2022). https://doi.org/10.48669/esys_2022-5.
- [3] Bundesministerium für Wirtschaft und Klimaschutz, Überblickspapier Osterpaket, 2022. https://www.bmwk.de/Redaktion/DE/Downloads/Energie/0406_ueberblickspapier_osterpaket.pdf?__blob=publicationFile&v=14 (accessed 10 August 2022).
- [4] Bundesministerium für Wirtschaft und Klimaschutz (Ed.), Gesetzentwurf der Bundesregierung: Entwurf eines Gesetzes zu Sofortmaßnahmen für einen beschleunigten Ausbau der erneuerbaren Energien und weiteren Maßnahmen im Stromsektor, 2022.
- [5] Ch. Lucha, L. Meinecke, Alte Energiewelt – Neue Energiewelt : Trends und Akteure in einem zunehmend digitalen Energiesystem, 2019. https://www.boell.de/sites/default/files/boll.brief_go9_alte_energiewelt_neue_energiewelt.pdf (accessed 27 September 2022).
- [6] German Parliament (Ed.), Gesetz zur Digitalisierung der Energiewende, 1st ed., Bonn, 29th 2016.
- [7] Bundesamt für Sicherheit in der Informationstechnik, Allgemeinverfügung zur Feststellung nach § 19 Abs. 6 Messstellenbetriebsgesetz: BSI, 2022.
- [8] A. Bogensperger, T. Estermann, S. Köppl, D. Wohlschlager, S. Faller, M. Müller, Smart Meter, Prosumer, Flexumer - Wie die Digitalisierung die Rolle von Verbrauchern ändert. Bericht zum Projekt C/sells, 2019. <https://www.ffe.de/veroeffentlichungen/smart-meter-prosumer-flexumer-wie-die-digitalisierung-die-rolle-von-verbrauchern-veraendert/> (accessed 27 September 2022).
- [9] D. Bauknecht, Ch. Heinemann, M. Koch, D. Ritter, R. Harthan, A. Sachs, M. Vogel, E. Tröster, S. Langanke, Systematischer Vergleich von Flexibilitäts- und Speicheroptionen im deutschen Stromsystem zur Integration von erneuerbaren Energien und Analyse entsprechender Rahmenbedingungen, Öko-Institut e. V; energy nautics GmbH 2016.
- [10] Ph. Sterchele, J. Brandes, J. Heilig, D. Wrede, Ch. Kost, T. Schlegl, A. Bett, H.-M. Henning, Studie: Wege zu einem klimaneutralen Energiesystem - Die deutsche Energiewende im Kontext gesellschaftlicher Verhaltensweisen, Fraunhofer-Institut für Solare Energiesysteme ISE (2020).
- [11] H. Zsiborács, G. Pintér, A. Vincze, Z. Birkner, N.H. Baranyai, Grid balancing challenges illustrated by two European examples: Interactions of electric grids, photovoltaic power generation, energy storage and power generation forecasting, Energy Reports 7 (2021) 3805–3818. <https://doi.org/10.1016/j.egyr.2021.06.007>.
- [12] H. Hahn, B. Krautkremer, K. Hartmann, M. Wachendorf, Review of concepts for a demand-driven biogas supply for flexible power generation, Renewable and Sustainable Energy Reviews 29 (2014) 383–393. <https://doi.org/10.1016/j.rser.2013.08.085>.

Referenzen

- [13] N. Hartmann, Rolle und Bedeutung der Stromspeicher bei hohen Anteilen erneuerbarer Energien in Deutschland. Dissertation, Stuttgart, 2013.
- [14] T. Barchmann, E. Mauky, M. Dotzauer, M. Stur, S. Weinrich, H.F. Jacobi, J. Liebetrau, M. Nelles, Expanding the flexibility of biogas plants – substrate management, schedule synthesis and economic assessment. LANDTECHNIK, Bd. 71 Nr. 6 (2016).
<https://doi.org/10.15150/LT.2016.3146>.
- [15] Geschäftsstelle der Arbeitsgruppe Erneuerbare Energien-Statistik (AGEE-Stat) am Umweltbundesamt, Erneuerbare Energien in Deutschland: Daten zur Entwicklung im Jahr 2020, 2021.
https://www.umweltbundesamt.de/sites/default/files/medien/5750/publikationen/2021_hgp_erneuerbareenergien_deutsch_bf.pdf (accessed 27 September 2022).
- [16] HInrich Neumann, Projekt Visuflex zeigt: Biogasanlagen könnten 30 GW flexible Leistung stellen, 2022. <https://www.topagrar.com/energie/news/projekt-visuflex-zeigt-biogasanlagen-koennten-30-gw-flexible-leistung-stellen-12863588.html> (accessed 13 August 2022).
- [17] Gesetz über den Ausbau Erneuerbarer Energien (Erneuerbare-Energien-Gesetz); §33i: EEG, in: BGBl. I S. 1634.
- [18] E. Mauky, S. Weinrich, H.-F. Jacobi, H.-J. Nägele, J. Liebetrau, M. Nelles, Demand-driven biogas production by flexible feeding in full-scale - Process stability and flexibility potentials, Anaerobe 46 (2017) 86–95. <https://doi.org/10.1016/j.anaerobe.2017.03.010>.
- [19] Fachagentur Nachwachsende Rohstoffe, Flexibilisierung von Biogasanlagen, 2018.
https://www.fnr.de/fileadmin/allgemein/pdf/broschueren/Broschuere_Flexibilisierung_Biogas_Web.pdf (accessed 27 September 2022).
- [20] L. Vogel, K. Sugul, F. Schünemeyer, B. Krautkremer, H. Hahn, H. F. Jacobi, C. Niemeier, K. Anduschus, A. Osterfeld, Schlussbericht: Verbundvorhaben: Upgrading von Bestandsbiogasanlagen hin zu flexiblen Energieerzeugern durch eine bedarfsorientierte Dynamisierung der Biogasproduktion (UBEDB) 2018.
- [21] H. Hahn, W. Ganagin, K. Hartmann, M. Wachendorf, Cost analysis of concepts for a demand oriented biogas supply for flexible power generation, Bioresour. Technol. 170 (2014) 211–220.
<https://doi.org/10.1016/j.biortech.2014.07.085>.
- [22] J. Grim, D. Nilsson, P.-A. Hansson, Å. Nordberg, Demand-Orientated Power Production from Biogas: Modeling and Simulations under Swedish Conditions, Energy Fuels 29 (2015) 4066–4075. <https://doi.org/10.1021/ef502778u>.
- [23] R. Maier, B. Thomas (Eds.), Optimierung einer intelligenten Steuerungsalgorithmik für Biogas-BHKW inklusive Feldversuchen an einer realen Biogasanlage: Tagungsband 17. Symposium Energieinnovation, 16.-18.02.2022, Graz/Austria, S. 1-11.
https://www.tugraz.at/fileadmin/user_upload/tugrazExternal/738639ca-39a0-4129-b0f0-38b384c12b57/files/lf/Session_E3/535_LF_Maier.pdf (accessed 07 Oktober 2022).
- [24] R. Maier, B. Thomas, Optimization of a flexible and robust algorithm for intelligent control of biogas CHP units including simulations and field tests: Progress in Biogas V, 22.-24.09.2022, Stuttgart.

Referenzen

- [25] S. Ruile, S. Schmitz, M. Mönch-Tegeder, H. Oechsner, Degradation efficiency of agricultural biogas plants--a full-scale study, *Bioresour. Technol.* 178 (2015) 341–349. <https://doi.org/10.1016/j.biortech.2014.10.053>.
- [26] N. Kythreotou, G. Florides, S.A. Tassou, A review of simple to scientific models for anaerobic digestion, *Renewable Energy* 71 (2014) 701–714. <https://doi.org/10.1016/j.renene.2014.05.055>.
- [27] industr.com, Mittels Datenanalysen Ereignisse in der Energiewirtschaft voraussagen: Digitalisierung der Energiewende, 2022. <https://www.industr.com/de/mittels-datenanalysen-ereignisse-in-der-energiewirtschaft-voraussagen-2645732> (accessed 21 September 2022).
- [28] A. Voß, Energieprognosen - Überflüssig oder sinnvoll?, 1983. <https://elib.uni-stuttgart.de/bitstream/11682/8145/1/vos78.pdf> (accessed 21 September 2022).
- [29] W. Schellong (Ed.), *Analyse und Optimierung von Energieverbundsystemen*, Springer Berlin Heidelberg, Berlin, Heidelberg, 2016.
- [30] R. Briegel, D. Filzek, P. Ritter, Ergebnisbericht AP 2.4 Last- und Erzeugungsprognose: Projekt RegModHarz. Ergebnisbericht, 2012. <https://silo.tips/download/stromlastprognose-ramon-briegel-dirk-filzek-peter-ritter-cube-engineering-gmbh-e> (accessed 27 September 2022).
- [31] M. Fiedeldej, *Analyse und Prognose elektrischer Lastgangzeitreihen*. Dissertation, Hannover, 2010.
- [32] C. Hirsch, *Fahrplanbasiertes Energiemanagement in Smart Grids*. Dissertation, 2015.
- [33] C. Bennett, R. Stewart, J. Lu, Autoregressive with Exogenous Variables and Neural Network Short-Term Load Forecast Models for Residential Low Voltage Distribution Networks, *Energies* 7 (2014) 2938–2960. <https://doi.org/10.3390/en7052938>.
- [34] A. Wenzel, *Komponentenzerlung des Regelleistungsbedarfs mit Methoden der Zeitreihenanalyse*. Masterarbeit, 2010.
- [35] C. Gerwig, *Optimierung der Energiebilanzen im Microgrid*. Dissertation, UVH - Universitätsverlag Hildesheim, 2017.
- [36] A. Tidemann, B. Hoverstad, H. Langseth, P. Öztürk, Effects of Scale on Load Prediction Algorithms, 22 nd International Conference on Electricity Distribution (2013).
- [37] R. Sevlian, R. Rajagopal, Short Term Electricity Load Forecasting on Varying Levels of Aggregation (2014). <https://doi.org/10.48550/arXiv.1404.0058>.
- [38] H.N. Gavala, I. Angelidaki, B.K. Ahring, Kinetics and modeling of anaerobic digestion process, *Adv. Biochem. Eng. Biotechnol.* 81 (2003) 57–93. https://doi.org/10.1007/3-540-45839-5_3.
- [39] A. Donoso-Bravo, J. Mailier, C. Martin, J. Rodríguez, C.A. Aceves-Lara, A. Vande Wouwer, Model selection, identification and validation in anaerobic digestion: a review, *Water Res.* 45 (2011) 5347–5364. <https://doi.org/10.1016/j.watres.2011.08.059>.
- [40] D.J. Batstone, *Modelling and control in anaerobic digestion: achievements and challenges*, Santiago de Compostela, Spain, 2013.
- [41] M. Lübken, M. Wichern, M. Schlattmann, A. Gronauer, H. Horn, Modelling the energy balance of an anaerobic digester fed with cattle manure and renewable energy crops, *Water Res.* 41 (2007) 4085–4096. <https://doi.org/10.1016/j.watres.2007.05.061>.

- [42] K. Koch, M. Lübken, T. Gehring, M. Wichern, H. Horn, Biogas from grass silage - Measurements and modeling with ADM1, *Bioresour. Technol.* 101 (2010) 8158–8165.
<https://doi.org/10.1016/j.biortech.2010.06.009>.
- [43] P. Biernacki, S. Steinigeweg, A. Borchert, F. Uhlenhut, Application of Anaerobic Digestion Model No. 1 for describing anaerobic digestion of grass, maize, green weed silage, and industrial glycerine, *Bioresour. Technol.* 127 (2013) 188–194.
<https://doi.org/10.1016/j.biortech.2012.09.128>.
- [44] K. Hagos, J. Zong, D. Li, C. Liu, X. Lu, Anaerobic co-digestion process for biogas production: Progress, challenges and perspectives, *Renewable and Sustainable Energy Reviews* 76 (2017) 1485–1496. <https://doi.org/10.1016/j.rser.2016.11.184>.
- [45] J. Lauwers, L. Appels, I.P. Thompson, J. Degève, J.F. van Impe, R. Dewil, Mathematical modelling of anaerobic digestion of biomass and waste: Power and limitations, *Progress in Energy and Combustion Science* 39 (2013) 383–402. <https://doi.org/10.1016/j.pecs.2013.03.003>.
- [46] E. Mauky, S. Weinrich, H.-J. Nägele, H.F. Jacobi, J. Liebetrau, M. Nelles, Model Predictive Control for Demand-Driven Biogas Production in Full Scale, *Chem. Eng. Technol.* 39 (2016) 652–664.
<https://doi.org/10.1002/ceat.201500412>.
- [47] L. Peters, P. Biernacki, W. Quaghebeur, F. Uhlenhut, S. Steinigeweg, Model-based control for a demand-driven biogas production to cover residual load rises, *Bioprocess Biosyst. Eng.* 42 (2019) 1829–1841. <https://doi.org/10.1007/s00449-019-02179-6>.
- [48] D. Gaida, C. Wolf, M. Bongards, Feed control of anaerobic digestion processes for renewable energy production: A review, *Renewable and Sustainable Energy Reviews* 68 (2017) 869–875.
<https://doi.org/10.1016/j.rser.2016.06.096>.
- [49] The World Bank - IBRD IDA, Energieverbrauch pro Kopf - Deutschland, 2022.
<https://data.worldbank.org/country/DE?locale=de> (accessed 22 September 2022).
- [50] E. Yukseltan, A. Yucekaya, A.H. Bilge, Forecasting electricity demand for Turkey: Modeling periodic variations and demand segregation, *Applied Energy* 193 (2017) 287–296.
<https://doi.org/10.1016/j.apenergy.2017.02.054>.
- [51] S. Ben Taieb, R. Huser, R.J. Hyndman, M.G. Genton, Forecasting Uncertainty in Electricity Smart Meter Data by Boosting Additive Quantile Regression, *IEEE Trans. Smart Grid* 7 (2016) 2448–2455. <https://doi.org/10.1109/TSG.2016.2527820>.
- [52] C. Widmann, D. Lödige, A. Toradmal, B. Thomas, Enabling CHP units for electricity production on demand by smart management of the thermal energy storage, *Applied Thermal Engineering* 114 (2017) 1487–1497. <https://doi.org/10.1016/j.applthermaleng.2016.08.065>.
- [53] D. Lödige, C. Widmann, B. Thomas, Stroomoptimierter Betrieb von KWK-Anlagen durch intelligentes Wärmespeichermanagement. Forschungsbericht, Reutlingen, 2015.
- [54] P. Haase, B. Thomas, Test and optimization of a control algorithm for demand-oriented operation of CHP units using hardware-in-the-loop, *Applied Energy* 294 (2021) 116974.
<https://doi.org/10.1016/j.apenergy.2021.116974>.
- [55] R. Maier, B. Thomas (Eds.), Flexible and robust control algorithm for intelligent control of biogas CHP units for stabilizing the power grid: European Biomass Conference and Exhibition Proceedings, ISBN 2282-5819, 6-9 July 2020, Virtual Conference, S. 894-900.

Referenzen

- [56] B. Wett, A. Eladawy, M. Ogurek, Description of nitrogen incorporation and release in ADM1, *Water Sci. Technol.* 54 (2006) 67–76. <https://doi.org/10.2166/wst.2006.527>.
- [57] S. Weinrich, M. Nelles, Systematic simplification of the Anaerobic Digestion Model No. 1 (ADM1) – Model development and stoichiometric analysis, *Bioresour. Technol.* (2021) 125124. <https://doi.org/10.1016/j.biortech.2021.125124>.
- [58] D. Batstone, J. Keller, I. Angelidaki, S. Kalyuzhnyi, S. Pavlostathis, A. Rozzi, W. Sanders, H. Siegrist, V. Vavilin, *Anaerobic Digestion Model No 1 (ADM1)*, IWA Publishing (London UK, 2002).
- [59] M. Schlattmann, Weiterentwicklung des „Anaerobic Digestion Model (ADM1)“ zur Anwendung auf landwirtschaftliche Substrate. Dissertation, 2011.
- [60] S. Weinrich, M. Paterson, U. Roth, Leitfaden zur Substrat- und Effizienzbewertung an Biogasanlagen: DBFZ Report Nr. 35, 2020. https://www.dbfz.de/fileadmin/user_upload/Referenzen/DBFZ_Reports/DBFZ_Report_35.pdf (accessed 27 September 2022).
- [61] B. Hülsemann, Development and Evaluation of Methods for Assessing the Efficiency of Biogas Plants. Dissertation, Stuttgart, 2022.
- [62] S. Weinrich, Praxisnahe Modellierung von Biogasanlagen. Dissertation, Rostock, 2017.
- [63] S. Weinrich, M. Nelles, Critical comparison of different model structures for the applied simulation of the anaerobic digestion of agricultural energy crops, *Bioresour. Technol.* 178 (2015) 306–312. <https://doi.org/10.1016/j.biortech.2014.10.138>.
- [64] P. Holubar, L. Zani, M. Hagar, W. Fröschl, Z. Radak, R. Braun, Modelling of anaerobic digestion using self-organizing maps and artificial neural networks, *Water Science and Technology* 41 (2000) 149–156. <https://doi.org/10.2166/wst.2000.0259>.
- [65] H. Abu Qdais, K. Bani Hani, N. Shatnawi, Modeling and optimization of biogas production from a waste digester using artificial neural network and genetic algorithm, *Resources, Conservation and Recycling* 54 (2010) 359–363. <https://doi.org/10.1016/j.resconrec.2009.08.012>.
- [66] L. Ljung, *Black-box models from input-output measurements*, Budapest, 2001.
- [67] M. Perrier, D. Dochain, Evaluation of control strategies for anaerobic digestion processes, *Int. J. Adapt. Control Signal Process.* 7 (1993) 309–321. <https://doi.org/10.1002/acs.4480070408>.
- [68] M.W. Barnett, J.F. Andrews, Expert System for Anaerobic-Digestion-Process Operation, *J. Environ. Eng.* 118 (1992) 949–963. [https://doi.org/10.1061/\(ASCE\)0733-9372\(1992\)118:6\(949\)](https://doi.org/10.1061/(ASCE)0733-9372(1992)118:6(949)).
- [69] P. Holubar, L. Zani, M. Hager, W. Fröschl, Z. Radak, R. Braun, Start-up and recovery of a biogas-reactor using a hierarchical neural network-based control tool, *J. Chem. Technol. Biotechnol.* 78 (2003) 847–854. <https://doi.org/10.1002/jctb.854>.
- [70] E. Lewinson, Choosing the correct error metric: MAPE vs. sMAPE, 2020. <https://towardsdatascience.com/choosing-the-correct-error-metric-mape-vs-smape-5328dec53fac> (accessed 7 October 2022).
- [71] S. Rijkers-Defrasne, T. von Versen, N. Malanowski, Herausforderungen Peer-to-Peer-Energiehandel in Deutschland. Potenziale, Herausforderungen und Ausblick: Working Paper Forschungsförderung, 2021.

Referenzen

<https://www.econstor.eu/bitstream/10419/232573/1/1752706498.pdf> (accessed 27 September 2022).