

ÖkARA – PROGNOSE-BASIERTE OPTIMIERUNGEN

Mit ÖkARA soll ein prognosebasiertes Optimierungstool für Abwasserreinigungsanlagen entstehen, das im Endzustand Echtzeit-Optimierungen erlaubt. Mithilfe von KI-Modellen werden die zur Prognose benötigten Messreihen gewonnen. Optimierungsalgorithmen dienen zur Findung einer optimalen Betriebseinstellung in Bezug auf Energie und Klima sowie auf Betriebskosten und Gewässerschutz.

*Martin Probst; Florian Hitz; Paul Brügger, Hunziker Betatech AG
Florin Barbisch; Martin Melchior, Fachhochschule Nordwestschweiz*

RÉSUMÉ

ÖkARA: OPTIMISATION BASÉE SUR DES PRÉVISIONS

Les données de mesure sont cruciales pour la sécurité et l'efficacité de l'exploitation des stations d'épuration (STEP). La disponibilité grandissante des données permet de débloquer de nouveaux potentiels d'optimisation opérationnelle, énergétique et économique. De plus, avec l'entrée en vigueur de la loi sur le climat et l'innovation, les gaz à effet de serre font l'objet d'une attention accrue, ce qui accentue les arbitrages entre énergie, coûts et protection des eaux. Les modèles physiques classiques sont coûteux et doivent être paramétrés un à un.

Le projet ÖkARA vise à développer un outil IA d'optimisation basé sur des prévisions qui apprend les caractéristiques spécifiques des STEP et s'adapte en permanence. Le sous-système «circuit de gaz» a été le premier objet étudié. Ont fait l'objet de prévisions la production de gaz, la consommation d'électricité et la production photovoltaïque pour calculer les points de commutation optimaux de la centrale de cogénération et ainsi réduire les coûts d'électricité.

Le modèle IA *Chronos2* a montré une plus grande précision de prévision que les modèles statistiques, même sans peaufinage, réduisant les commutations de la centrale et les coûts. Il reste à travailler sur la qualité des données, leur disponibilité à long terme et la documentation. À terme, l'objectif est une optimisation en temps réel afin d'exploiter systématiquement le potentiel inutilisé.

EINLEITUNG

Messdaten sind für die Überwachung und den ordnungsgemässen Betrieb einer Abwasserreinigungsanlage (ARA) unerlässlich. In den letzten Jahren hat sich die Datenverfügbarkeit deutlich verbessert, wodurch immer mehr automatisierte Messdaten für mehr Parameter erfasst werden. In diesem Zusammenhang stellt sich die Frage, welches betriebliche, energetische und wirtschaftliche Optimierungspotenzial ungenutzt in den heute verfügbaren Daten steckt.

Bereits vor einiger Zeit wurde mit dem Handbuch «Energie in ARA» das energetische Optimierungspotenzial von Abwasserreinigungsanlagen aufgezeigt. Spätestens seit dem Inkrafttreten des Klima- und Innovationsgesetzes (KIG) rückt nun auch die Reduktion von Treibhausgasemissionen auf ARA verstärkt in den Fokus. Diese Erweiterung der Betrachtungsfelder führt nicht nur zu zunehmend komplexen Wechselwirkungen zwischen betrieblichen Anpassungen oder umgesetzten baulichen Massnahmen und Auswirkungen auf den Betrieb der ARA. Es ergeben sich dadurch auch vermehrt Zielkonflikte (Energie, Wirtschaftlichkeit, Gewässerschutz).

Derzeit werden diese Zusammenhänge zwischen Massnahmen und Auswirkungen des komplexen ARA-Gefüges grösstenteils mit physikalischen Modellen dynamisch abgebildet, da stati-

Kontakt: M. Probst; martin.probst@hunziker-betatech.ch

(© AdobeStock)

sche Berechnungen zunehmend an ihre Grenzen stossen. Diese Modelle müssen jedoch für jede ARA individuell parametrisiert und validiert werden, was mit erheblichem zeitlichem und fachlichem Aufwand verbunden ist.

VISION VON ÖKARA

Ziel des ÖKARA-Projekts ist die Entwicklung eines prognosebasierten Optimierungstools. Dieses soll mit möglichst geringem Anpassungsaufwand auf unterschiedliche ARA anwendbar sein. Künstliche Intelligenz (KI) soll dabei helfen, die charakteristischen Eigenschaften einer ARA datenbasiert zu erlernen und so den Aufwand der individuellen Modellanpassung deutlich zu reduzieren. Ausserdem wird angestrebt, dass sich das KI-Modell durch regelmässig wiederkehrende oder gar Echtzeit-Aktualisierungen der Trainingsdaten an veränderte Rahmenbedingungen anpassen kann. Das Tool soll zudem kontinuierlich Optimierungsvorschläge generieren, die auf den berechneten Prognosen basieren. Mit dem neuen Tool soll das bisher ungenutzte Optimierungspotenzial gezielt ausgeschöpft werden. Ohne den Einsatz von KI wäre zur Umsetzung dieser Vision vermutlich ein digitaler Zwilling erforderlich, was bereits bei einer einzigen Kläranlage einen enormen Aufwand bedeutet [1].

PROGNOSEBASIERTES OPTIMIERUNGSTOOL

POTENZIALABSCHÄTZUNG TEILSYSTEME

Zur verbesserten Nachvollziehbarkeit und Reduktion der Gesamtkomplexität werden die ARA in verschiedene Teilsysteme unterteilt, die jeweils eigenständige Zielgrössen für die Optimierung aufweisen. Diese Teilsysteme sollten zunächst einzeln betrachtet und in einem späteren Schritt miteinander verknüpft werden. Damit ein Teilsystem für eine reale Umsetzung der Optimierung geeignet ist, müssen zwei Voraussetzungen erfüllt sein:

- Der finanzielle oder ökologische Nutzen muss ausreichend gross sein.
- Das Teilsystem muss konkrete Möglichkeiten zur Einflussnahme bieten.

Als besonders herausfordernd erwies sich die Abschätzung des potenziellen Nutzens. Dies liegt unter anderem daran, dass bei einflussreichen Teilsystemen – wie beispielsweise der biologischen Reinigung – zahlreiche relevante Parameter nicht automatisch und kontinuierlich gemessen werden (z.B. Schmutzstoffparameter oder die Schlammzusammensetzung für den momentanen Sauerstoffbedarf und damit den Stromverbrauch der Gebläse). Damit eignet sich zum Beispiel die bio-

logische Reinigung aktuell nur sehr eingeschränkt für einen datengetriebenen Optimierungsansatz.

TEILSYSTEM «GASKREISLAUF»

Als Anwendungsbeispiel wurde aufgrund der guten Datenverfügbarkeit sowie der sich dynamisch entwickelnden Energiepreise der «Gaskreislauf» ausgewählt. Im gezeigten Fall wurde davon ausgegangen, dass der Energieverbrauch der ARA bereits weitgehend optimiert ist und durch gezielte Einstellung der Schaltpunkte des Blockheizkraftwerks (BHKW) die Nettostromkosten weiter reduziert werden können (Optimierungsziel). Das Teilsystem ist schematisch in *Figur 1* dargestellt.

Für das Teilsystem «Gaskreislauf» wurden Inputgrössen identifiziert, deren Prognosen relevant sind für die Optimierungsergebnisse. Im vorliegenden Anwendungsbeispiel sind dies die Gasproduktion in der Faulung, der Stromverbrauch der Verbraucher im Abwasserbereich, die Stromproduktion der Photovoltaikanlage (PVA) sowie die Strompreise. Alle diese Inputgrössen sind dynamisch. Basierend auf diesen Prognosen sollten mit dem Optimierungsalgorithmus die optimalen Schaltpunkte des BHKW für die nachfolgenden Tage ermittelt werden. Als Optimierungskriterium dienen die Nettostromkosten.

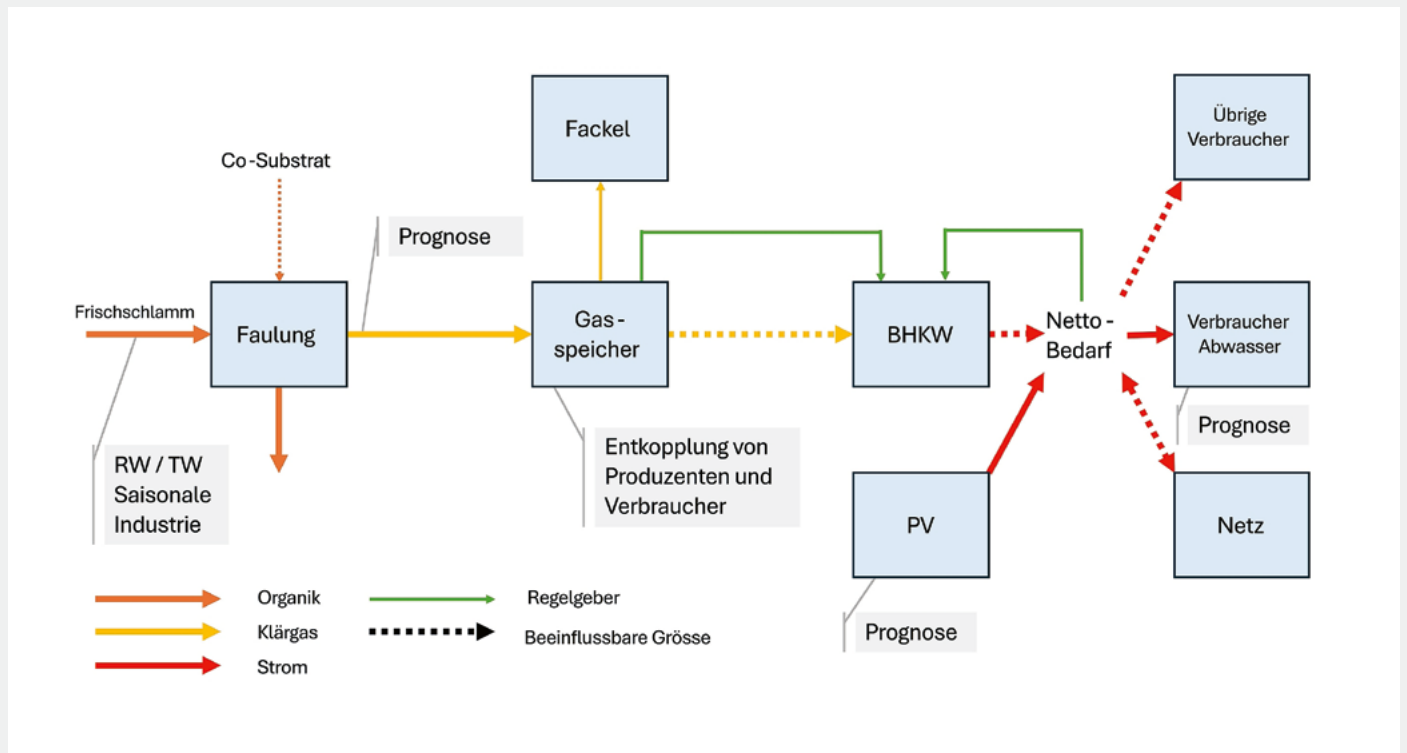


Fig. 1 Schematische Darstellung des Teilsystems Gaskreislauf für das Anwendungsbeispiel.

DATENBESCHAFFUNG

Im Rahmen des Projektes ÖKARA wurde die kürzlich neu geschaffene Schnittstelle für das Abfragen (s. Artikel «Standardisierte Schnittstelle für Prozessdaten» S. 35 diese Ausgabe) von Messdaten auf Kläranlagen konkret angewandt. Die dadurch gewonnene einheitlichen Datenstruktur erleichterte das Trainieren von KI-Modellen. Mit den zur Verfügung stehenden Daten in «Echtzeit» konnten die Modelle mit aktuellen Betriebsdaten laufend validiert werden.

Sensorik

Durch die Verfügbarkeit von Daten unterschiedlicher ARA konnten die KI-Modelle in unterschiedlichen Umgebungen getestet werden. Ohne diese Möglichkeit bestünde die Gefahr, dass Modelle nur eingeschränkt übertragbar sind: KI-Modelle lernen lediglich ein gewisses Verhalten der Daten auswendig. Sollen die KI-Modelle nun Daten voraussagen, die sie noch nie gesehen haben und dazu noch von einer anderen ARA stammen, kann die Genauigkeit abnehmen. Im Kapitel «Prognose Algorithmen» wird gezeigt, dass das gewählte KI-Modell (Chronos2) weniger Probleme mit diesem Phänomen hat.

Zur Sicherstellung der Korrektheit wurden ergänzende Berechnungsmodelle implementiert, die nicht gemessene aus vorhanden Daten berechnen. Künftig könnten KI-Modelle interessant sein, um Messgrößen, die teure Sensorik erfordern würden, zu ergänzen.

Echtzeit

Durch die neue Datenschnittstelle konnten reale Daten für Input-/Kovariaten-Tests, Validierungen und Fehleranalysen der Prognose-Algorithmen nach Belieben beschafft werden. Somit konnte auch der Einfluss einzelner Parameter auf die Prognose-Genauigkeit der Algorithmen getestet werden (s. Kap. «Fehleranalyse»). Längerfristig sollen die Prognose-Algorithmen in Echtzeit auf Betriebsdaten zugreifen können, damit die Optimierung laufend und automatisiert erfolgen kann. Ohne die Datenschnittstelle müsste dabei immer der ganze Datensatz erneut heruntergeladen werden, was aufwändig und mit Latenzzeiten verbunden ist.

Meteo-Daten

Neben ARA-Daten wurden Meteo-Prognosen (openweathermap)¹ in die Modelle miteinbezogen. Bei Meteorvorhersagen

nimmt die Prognosegenauigkeit ab, je weiter diese in der Zukunft liegen.

DATENAUFBEREITUNG

Für das vorliegende Anwendungsbeispiel stand ab Oktober 2024 über einen Zeitraum von 14 Monaten ein Datensatz einer ARA zur Verfügung.

Zwecks der schrittweisen Simulation und den von den Autoren gestellten Anforderungen wurden die Messreihen auf ein einheitliches 15-Minuten-Raster harmonisiert. Die Entscheidung für diese hohe Auflösung fiel, um qualitative Aussagen über die Präzision der Modelle machen zu können. Je grösser das Zeitintervall der Trainingsdaten, desto einfacher ist es, genaue Modelle zu erhalten (Aggregation reduziert Varianz). Ein grösseres Zeitintervall würde zwar die Prognosegenauigkeit erhöhen, jedoch die operative Steuerbarkeit des BHKW einschränken.

Anschliessend wurden die Daten auf Vollständigkeit und Plausibilität geprüft. Im Fokus stand dabei die mathematische Konsistenz zwischen Gasproduktion, Gasverbrauch und Speicherverhalten.

¹ <https://openweathermap.org/>

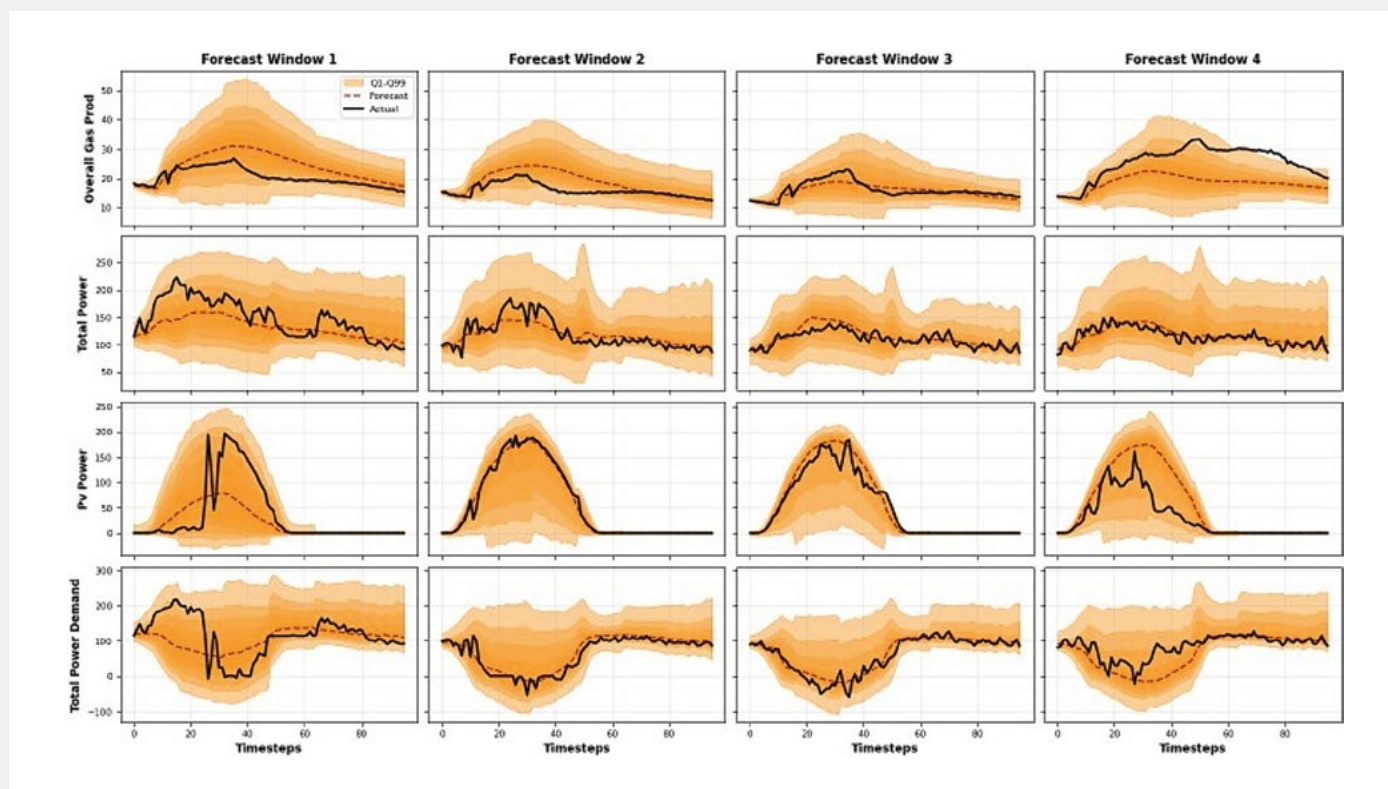


Fig. 2 Zufällig ausgewählte Zeitabschnitte des Chronos2-Modells für die Vorhersage von Gasproduktion, Energieproduktion, PV-Produktion und Energie-Nachfrage (von oben nach unten). Die orangen Flächen stellen dabei die Quantile Q1-Q99 dar. Die schwarze Linie ist der tatsächliche Wert, die gestrichelte rote Linie der Median der Vorhersage des Modells. Einheit der x-Achse ist die Anzahl 15-Minuten-Messungen, somit entsprechen die Teilstriche etwa einem Tag.

Physikalisch ungültige Messwerte, wie eine negative Gasproduktion, wurden durch Durchschnittswerte der angrenzenden Messwerte ersetzt. Solche Werte traten über die ganze Zeitreihe gesehen selten auf und beeinflussten die Dynamik daher nur geringfügig.

ALGORITHMEN

Das prognosebasierte Optimierungstool stützt sich auf zwei separaten Algorithmen: ein Algorithmus für die Prognose und ein zweiter für die Optimierung. Der Prognose-Algorithmus (KI) prognostiziert aufgrund von verschiedenen Messwerten (Inputdaten) eine definierte Zielgröße. Für das Anwendungsbeispiel am Teilsystem «Gaskreislauf» sind dies die Klärgasproduktion, die Stromproduktion der Photovoltaik-Anlage sowie der Energieverbrauch der ARA. Für die laufende (Echtzeit-)Optimierung (zweiter Algorithmus) werden diese prognostizierten Daten wiederum als Inputdaten benötigt. Der Optimierungs-Algorithmus sucht im Anwendungsbeispiel die optimalen Schaltpunkte für das BHKW, um

Fehlermetrik	Formel	Beschreibung
Mean Absolute Error (MAE)	$\frac{1}{n} \sum G_t - \widehat{G}_t $	Durchschnittliche absolute Abweichung der Gasproduktion pro Zeitschritt.
Root Mean Square Error (RMSE)	$\sqrt{\frac{1}{n} \sum (G_t - \widehat{G}_t)^2}$	Wie MAE, aber grosse Fehler werden stärker gewichtet.
Mean Absolute Percentage Error (MAPE)	$\frac{1}{n} \sum \left \frac{G_t - \widehat{G}_t}{G_t} \right $	Durchschnittlicher prozentualer Fehler; instabil bei sehr kleinen oder Null-Werten.
Mean Absolute Scaled Error (MASE)	$\frac{\sum G_t - \widehat{G}_t }{\sum G_t - G_{t-1} }$	Vergleich mit einer nativen Referenz (Wert von vor 15 Minuten). MASE < 1 ist besser als naiv.
Relative Mean Absolute Error (RMAE)	$\frac{\sum G_t - \widehat{G}_t }{\sum G_t }$	Mittlerer absoluter Fehler relativ zur typischen Zielgröße (robuster als MAPE).

Tab. 1 Beschreibung der Fehler-Metriken. G_t beschreibt die gemessenen Klärgasproduktion \widehat{G}_t die prognostizierte Klärgasproduktion. n beschreibt die Anzahl betrachteter 15-Minuten-Zeitpunkte.

die Stromkosten der Gesamtanlage zu minimieren.

PROGNOSE-ALGORITHMEN (KI)

Als Prognose-Algorithmen wurden rein statistische Modelle (Baseline) mit dem KI-Modell Chronos2 verglichen. Das KI-Modell Chronos2 ist ein leistungsstarkes

Foundational Model.² Es wurde vom Entwickler zuerst auf vielen – thematisch unabhängigen – Zeitreihen vortrainiert und kann danach durch den Anwender

² Chronos: <https://www.amazon.science/code-and-datasets/chronos-learning-the-language-of-time-series>

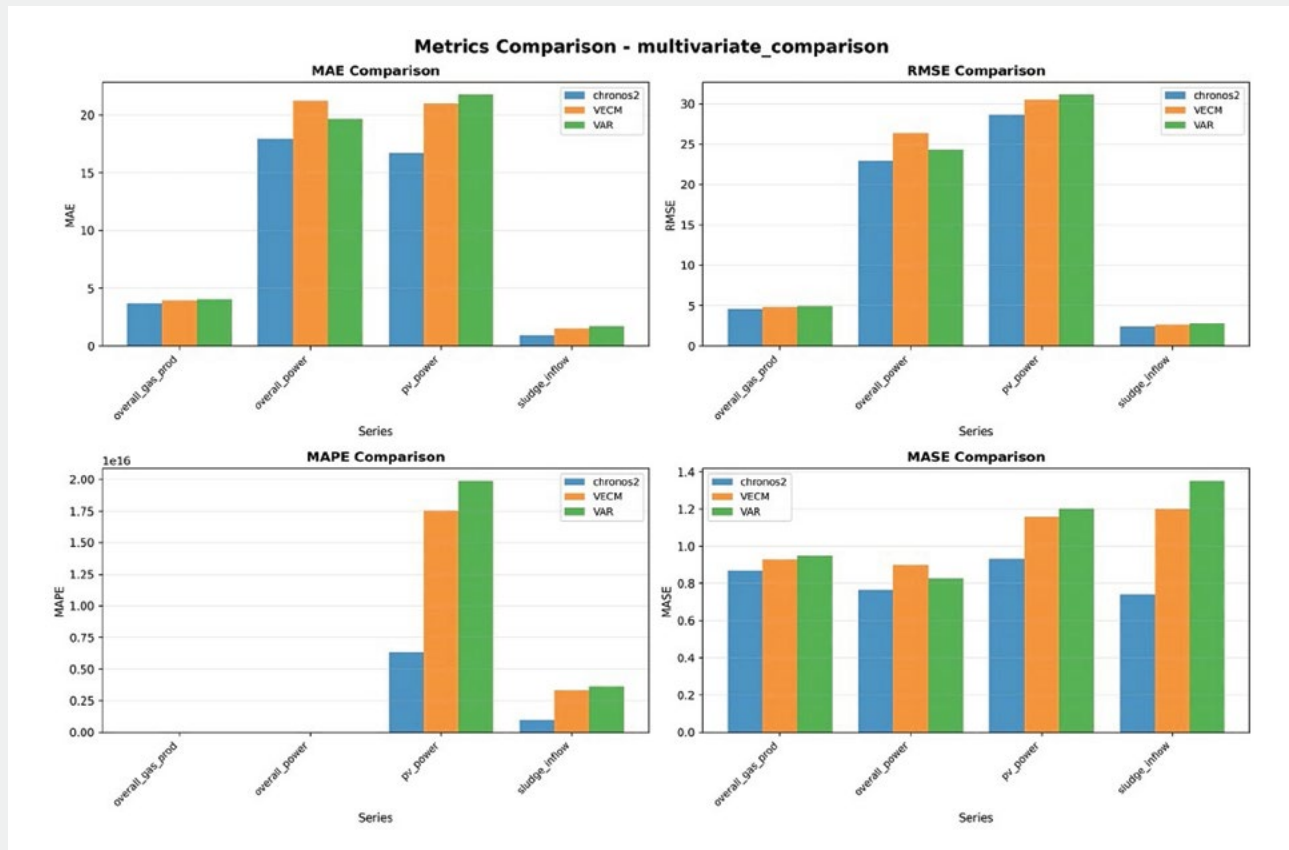


Fig. 3 Vergleich der Fehler zwischen zwei statistischen Modellen (Baseline, orange und grün) und dem KI-Modell Chronos2 (blau) mit verschiedenen gängigen Fehler-Metriken. Für alle Metriken gilt für die y-Achse: Tiefer ist besser. Balken pro Grafik von links nach rechts: Fehler Gasproduktion, Fehler Energieproduktion, Fehler PV-Produktion, Fehler Schlammzufluss. Unten links: Gasproduktion und Gesamtenergie wurden nicht mit MAPE ausgewertet.

auf ARA-Daten fein abgestimmt werden. Ähnlich wie Prompts bei *Large Language Models* werden bei *Chronos* Zeitreihen in Tokens zerlegt.

Mit *Chronos2* wurde der Verlauf der Gasproduktion, die Stromproduktion der PVA und der Gesamtstromverbrauch der nächsten sieben Tage mit einer zeitlichen Auflösung von 15 Minuten prognostiziert. Als Beispiel sind die Prognosen mit dem KI-Modell *Chronos2* in *Figur 2* dargestellt. In *Figur 3* ist die Prognosegenauigkeit der statistischen Modelle (Baseline) und des KI-Modells *Chronos2* gegenübergestellt. Es wird ersichtlich, dass das KI-Modell *Chronos2* für alle prognostizierten Größen ein tiefere Fehlerquote aufweist als die beiden statistischen Modelle *Vector Autoregressive* (VAR) und *Vector Error Correction Model* (VECM). Die hier gezeigten *Chronos2*-Vorhersagen basieren auf «zero-shot-learning», also ohne Feinabstimmung auf die ARA-Daten. Angesichts der bereits guten Resultate mit der *Zero-Shot*

Evaluation ist das *Chronos2*-Modell insbesondere für Vorhersagen in komplexen Teilsystemen vielversprechend. Für eine kurze Beschreibung der benutzten Fehler-Metriken in diesem Bericht siehe *Tabelle 1*.

FEHLERANALYSE

Um bei *Chronos2* die Prognosegenauigkeit zu erhöhen, wurden verschiedene Analysen durchgeführt.

Die Bewertung der Genauigkeit erfolgt über den «relativen mittleren absoluten Fehler» (RMAE) (s. auch *Tab. 1*) sowie über eine Residuenanalyse. In der Residuenanalyse werden die Abweichungen der prognostizierten Klärgasproduktion zur gemessenen Klärgasproduktion (Residuen) alle 15 Minute gemittelt. So ist ersichtlich, wie gross der Fehler einer Prognose von vier Stunden verglichen mit vier Tagen in die Zukunft ist. Durch diese visuelle Darstellung des RMAE können systematische Fehlprognosen über die Zeit

erkannt werden. Dieser relative Fehler für die Klärgasproduktion von *Chronos2* über einen Prognosezeitraum von einer Woche ist in *Figur 4* zu sehen. Auffällig ist der zu Beginn kleine Fehler, der dann stark ansteigt. Ausserdem schwankt der Fehler stark im Tagesverlauf: So gibt es einen Ausschlag am Morgen und am Abend. Das sind auch die Zeitpunkte, an denen die Gasproduktion jeweils stark zu- oder abnimmt. Der Eintrittszeitpunkt dieser sprunghaften Veränderung tritt täglich zu unterschiedlichen Zeiten ein. Die zeitlich variierende Lastenwechsel können nicht genau antizipiert werden, was zu erhöhten relativen Fehlern führt. *Chronos2* kann mehr als eine Einflussgrösse (Kovariate) für die Prognose einer Zielgrösse verwenden. Es wurde untersucht, ob und mit welchen Inputparametern die Prognose verbessert werden kann. Es hat sich gezeigt, dass sich die Prognosegenauigkeit ab einer bestimmten Anzahl Einflussgrössen wieder verschlechtert. Eine systematische Reduktion der Einflussgrössen ist also von zentraler Bedeutung. In *Figur 5* sind die Einflussgrössen – zusätzlich zur Gasproduktion – aufgeführt, mit denen das KI-Modell *Chronos2* die Gasproduktion am genauesten vorhersagt.

Eine weitere Analyse betrifft die Dauer der Historie, die das Modell für die Vorhersage verwendet. Es hat sich herausgestellt, dass zum Beispiel für die Prognose der Gasproduktion eine Verlängerung der Historie ab 15 Tagen eine verschwindend geringe Verbesserung der Genauigkeit hervorruft.

Die Fehleranalyse zeigt uns, dass für eine verbesserte Prognose unbekannte externe Einflussgrössen (z.B. Abwasserzusammensetzung, Handydaten, Verkehrsdaten etc.) relevant sein könnten, da mit internen Einflussgrössen keine deutliche Verbesserung der Prognosegenauigkeit erzielt werden konnten. Das KI-Modell *Chronos2* hat bessere Resultate als das statistische Modelle erzielt. Die Auswirkungen dieser Prognosefehler auf die resultierende Optimierung wurden daher in Simulationen mit realen Betriebsdaten plausibilisiert.

OPTIMIERUNGS-ALGORITHMEN

Im Kapitel «Prognose-Algorithmen» wurde das Vorgehen zum Einsatz der KI-Modelle im Teilsystem «Gaskreislauf» vorgestellt. Die mit KI-Modellen prognostizierten Daten sollen für die geplante

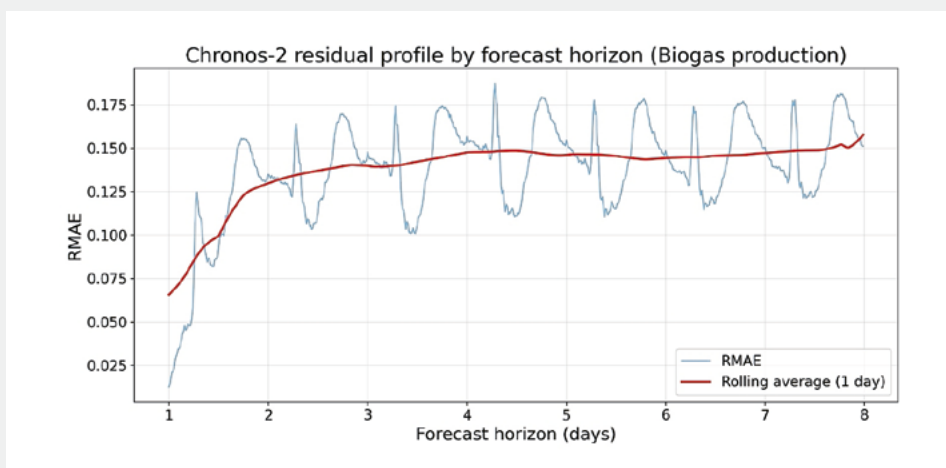


Fig. 4 Darstellung der Residuenanalyse einer 7-Tage-Prognose der Biogasproduktion. Mit zunehmendem Prognosehorizont steigt nimmt die Ungenauigkeit zu. Es ist allerdings anzumerken, dass sich der Fehler sublinear entwickelt.

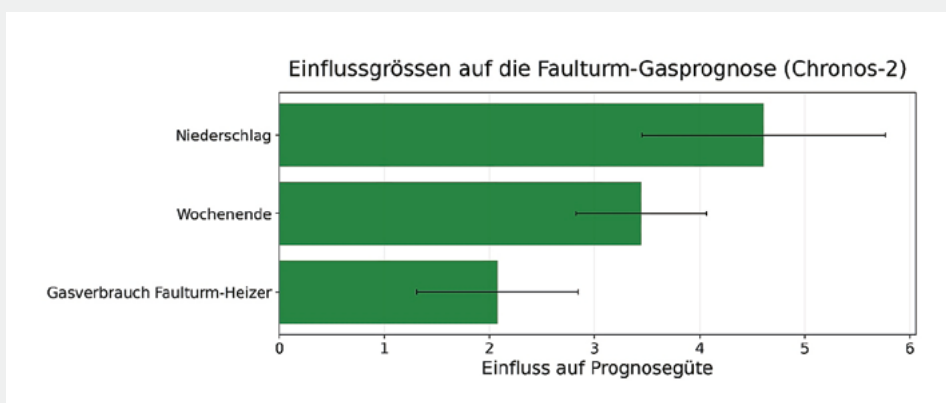


Fig. 5 Die drei Grössen mit dem mit Abstand grössten Einfluss auf die Faulturm-Gasprognose von *Chronos2*. Die vorherzusagende Messreihe – in diesem Fall die Gasproduktion im Faulturm – muss dem *Chronos2*-Modell zwingend mitgegeben werden. Die Balken zeigen das 95%-Konfidenzintervall.

	Stromkosten [Fr. / mt]	Einschaltungen [# / mt]
Optimiert	3600.-	73
Ist-Daten	4650.-	169

Tab. 2 Auswertung des Optimierungsprogramms. Dargestellt sind die Kosten ohne Optimierung (Ist-Daten) und die Kosten der besten Optimierungen. Die Anzahl der Ein- und Ausschaltungen des BHKW wurden um mehr als die Hälfte reduziert, was die Maschine schont. Alle Zahlen sind pro Monat.

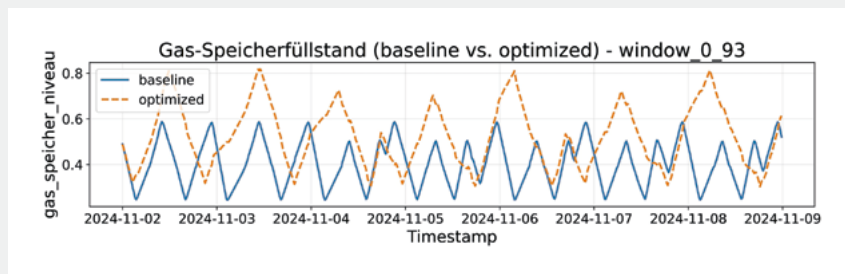


Fig. 6 Gemessener und simulativ berechneter Gas-Speicherfüllstand. Klar zu sehen ist, dass das BHKW weniger eingeschaltet wird.

Echtzeit-Optimierung eingesetzt werden. Für den Test der Optimierungs-Algorithmen erfolgte die Optimierung basierend auf den gemessenen Zeitreihen (Betriebsdaten) und nicht auf den Prognosedaten, da die Optimierungsparameter keinen Einfluss auf die Prognose haben und so ein Vergleich zu den echten Messdaten hergestellt werden konnte.

Die Optimierung versteht sich als Berechnung einer Anzahl Szenarien, bis eine definierte Zielgrösse minimiert oder maximiert ist. Im vorliegenden Anwendungsfall für den Gaskreislauf wurden die Nettostromkosten der ARA als Zielfunktion gewählt. Neben der Minimierung der Nettostromkosten wurde auch die Minimierung der Schalthäufigkeit der BHKW untersucht. Die Zielfunktion wurde mittels Anpassung des 2-Punkte-Reglers des BHKW, der sich auf den Füllstand im Gasspeicher bezieht, optimiert.

RESULTATE

Als Resultate werden die optimalen Schwellenwerte für das Ein- und Ausschalten des BHKW ausgegeben, die vom Personal eingestellt werden können. Ausserdem gibt das Programm die Kos-

ten und Einschaltungen im optimierten und nicht-optimierten Zustand an (s. Tab. 2). Die Kosten wurden mit den aktuell gültigen Bezugs- und Einspeisetarife berechnet.

Figur 6 zeigt den beispielhaften Verlauf des Gasspeicherfüllstands ohne und mit der Optimierung. Die ARA hat die Schwellenwerte des 2-Punkte-Reglers bereits an die Stromproduktion der PVA angepasst, daher gibt es auch in der Baseline zwei unterschiedliche Spitzen in der Kurve. Die Grafik verdeutlicht, wie mit den optimierten Schwellenwerten die Anzahl Einschaltungen des BHKW von täglich etwa 2-3 auf 1-1,5 reduziert werden kann.

FAZIT UND AUSBLICK

Es wurde ein funktionierendes Werkzeug aufgebaut, mit dem Zeitreihen mit KI-Modellen prognostiziert und Optimierungsfunktionen definiert werden können. Für die zwei untersuchten Anlage resultierte im Teilsystem «Gaskreislauf» eine Kosteneinsparung von rund 5-10%. Mit dem Einsatz von KI-Prognosen bestehen dabei aber Unsicherheiten, die sich im realen Betrieb klären müssen. Die Implementa-

tion und der Betrieb gemäss optimiertem Konzept wird im nächsten Schritt «real» umgesetzt und geprüft.

Die grösste Herausforderung für weitere Anlagen und Systeme liegt in der Datenverfügbarkeit und in der gleichbleibenden Datengüte über längere Zeiträume. Die Prozessleitsysteme speichern zwar historische Daten, sind aber nicht auf eine Archivierung der Daten ausgelegt. Bisher lag der Fokus bei Datenauswertungen auf Tageswerten, weshalb hochaufgelöste historische Daten noch nicht zwingend über lange Zeiträume verfügbar sind. Ausserdem ändern sich die Betriebsmodi auf der Kläranlage verhältnismässig häufig und sind nicht vollständig dokumentiert, da die Regelparameter der einzelnen Maschinen (wie die Schwellenwerte der BHKW 2-Punkte-Regler) im PLS üblicherweise nicht aufgezeichnet werden. Hinzu kommen ungeplante Ausfälle und manuelle Manipulationen von Aggregaten. Diese lassen sich schwer und nur zum Teil durch Datenanalysen rekonstruieren (zum Beispiel die eingestellten Schwellenwerte des BHKW über eine Analyse des Gasspeicherniveaus bei Aus-/Einschalten des BHKW).

Längerfristig wird eine ständig laufende, Echtzeit-Optimierung angestrebt. Dafür sind einerseits noch einige Punkte in der Steuerungstechnik, z. B. geeignete Periodizität der Parametereinstellungen, zu klären. Andererseits wäre fallweise ein Paradigmenwechsel bei der Programmierung nötig, damit die Anlagen einfach und laufend eingestellt werden können. Es bleibt zu hoffen und darauf hinzuwirken, dass die Datenaufzeichnung und -verfügbarkeit für die komplexeren Systeme laufend verbessert wird, damit das schlummernde Potenzial genutzt werden kann.

BIBLIOGRAPHIE

- [1] Hug, T.; Steinemann, R. (2023): Ein Flugsimulator für die ARA – Ein digitaler Zwilling unterstützt die dynamische SBR-Anlage der ARA Oberengadin. *Aqua & Gas* 3/23: 22-30

GEO BOX

GEOBOX GIS Module – Effiziente Verwaltung für Ihre Leitungs- und Kanalinfrastruktur

