

Anwendung von neuronalen Netzen für Assistenzsysteme in der Abwasserbehandlung

Optimierung der biologischen Behandlungsstufe

Felix Schmalenbach^{1,*}, Regina Gnirss¹, Mike Wilde-Lienert¹,
und Andreas Nink²

¹Berliner Wasserbetriebe, Deutschland

²Xylem Water Solutions Deutschland GmbH, Deutschland

*Correspondence: Felix Schmalenbach, felix.schmalenbach@bwb.de

Abstract. Die Berliner Wasserbetriebe (BWB) haben sich das Ziel gesetzt, bis 2030 klimaneutral zu arbeiten und die Energiewende zu unterstützen. Großes Optimierungspotenzial für die Abwasserreinigung liegt in der biologischen Behandlungsstufe, welche mit ca. 60 % den größten Energieverbrauch hat. Im Kooperationsprojekt „ANNA“ wurde erstmals die Belüftungssteuerung der biologischen Reinigungsstufe unter Anwendung künstlicher neuronaler Netze (KNN) in einer ausgewählten Prozesslinie auf dem Klärwerk Münchehofe untersucht. Ziel des Projektes war es, ein am Markt erhältliches Echtzeitassistenzsystem zur Reduzierung des Energieverbrauchs bei gleichzeitiger Einhaltung der Grenzwerte unter Betriebsbedingungen zu testen. Zur Modellierung des Prozesses kamen KNN zum Einsatz, um die Ablaufkonzentration der Versuchslinie zu prognostizieren. Die KNN wurden mit physikalisch relevanten historischen Daten trainiert. Mit Hilfe der modellbasierten Prognosen ließen sich Vorschläge für Soll-Sauerstoffkonzentration oder Soll-Luftmengen berechnen und umsetzen. Die Implementierung des Assistenzsystems erfolgte schrittweise. Im ersten Schritt wurde die Anwendung des Assistenzsystems manuell getestet. Die vom Betriebspersonal umgesetzten Handlungsempfehlungen führten zu einem reduzierten Luftverbrauch von ca. 10 %. Gleichzeitig wurde eine Erhöhung der Ammoniumkonzentration (NH₄-N) im Ablauf der Versuchslinie (2,2 mg/l) im Vergleich zur Vergleichslinie (1,6 mg/l) um 0,6 mg/l festgestellt. Innerhalb der Versuchsphase wurde die Abwasserbeaufschlagung in der Versuchs- und Vergleichslinie teilweise um 10 % erhöht. Hierbei konnte beobachtet werden, dass die Handlungsempfehlungen eine präzise frachtbasierte Belüftungssteuerung ermöglichten. Auch Regenereignisse erkannte das Assistenzsystem frühzeitig, wodurch rechtzeitig, entsprechend des eintretenden Frachtstosses, die Belüftung erhöht und anschließend wieder herabgesetzt wurde. Auf Grundlage der positiven Ergebnisse wurde das Assistenzsystems in den automatischen Betrieb genommen, um seinen Einfluss auf das Optimierungspotenzial und die Ablaufqualität zu untersuchen.

Keywords: Künstliche neuronale Netze, Abwasserbehandlung, Assistenzsystem

1. Einleitung

Die Berliner Wasserbetriebe (BWB) haben sich das Ziel gesetzt, bis 2030 klimaneutral zu arbeiten und die Energiewende zu unterstützen. Großes Optimierungspotenzial für die Abwasserreinigung liegt in der biologischen Behandlungsstufe, welche mit ca. 60 % den größten

Energieverbrauch hat. Der Energieverbrauch der Belüftung wird bei den BWB regelmäßig gemäß DWA-A 216 und DWA -M 209 untersucht. [1–3] Effiziente Regelkonzepte nach Soll-Sauerstoffkonzentrationen wurden dabei umgesetzt. Weiterhin bieten sich datengetriebene Modelle wie künstliche neuronale Netze (KNN) für eine Optimierung der Belüftungssteuerung an. Mit Hilfe von historischen und Echtzeit gemessenen Daten sind KNN in der Lage, Ablaufkonzentrationen zu prognostizieren. In Kombination mit Optimierungsalgorithmen lassen sich Stellgrößen für eine Optimierung des Betriebs berechnen. Während Sensordaten Informationen über den Behandlungsprozess bereitstellen, unterstützen solche Assistenzsysteme das Betriebspersonal um den Energieverbrauch bei gleichzeitiger Erhaltung der Reinigungsleistung zu reduzieren. [4, 5] Im Kooperationsprojekt „ANNA“ wurde daher erstmals die Belüftungssteuerung der biologischen Reinigungsstufe unter Anwendung von KNN in einer ausgewählten Prozesslinie auf dem Klärwerk Münchehofe untersucht. Das Klärwerk Münchehofe ist für 47.000 m³/d Abwasser dimensioniert, was einem Einwohnergleichwert von ca. 350.000 EW entspricht (Größenklasse 5). Der tägliche Wasserverbrauch in Berlin beträgt durchschnittlich 113 Liter pro Person [6]. Ziel des Projektes war es, ein am Markt erhältliches Assistenzsystem zur Reduzierung des Energieverbrauchs und Fällmittels bei gleichzeitiger Einhaltung der Grenzwerte unter Betriebsbedingungen zu testen. Hierbei wurden mit Hilfe modellbasierter Prognosen Vorschläge für Soll-Sauerstoffkonzentration oder Soll-Luftmengen für eine von acht Prozesslinien berechnet und umgesetzt.

2. Material & Methoden

Zur Modellierung des Prozesses kamen KNN zum Einsatz, um die Ablaufkonzentration der Versuchslinie in Echtzeit zu prognostizieren. Der Fokus lag dabei auf den Ablaufkonzentrationen von Ammonium (NH₄-N), Nitrat (NO₃-N) und ortho-Phosphat (PO₄-P). Für jede Zielgröße wurde ein separates Modell mit den jeweils physikalisch relevanten Parametern trainiert. Durch diese Trennung wird das Echtzeitassistenzsystem robuster; beispielsweise ist es bei einem Ausfall der PO₄-P-Messung möglich, dass die Prognosen der NH₄-N- und NO₃-N-Modelle weiterhin verfügbar bleiben.

2.1 Trainingsdaten

Für das Trainieren der Modelle wurde ein Datensatz mit Sensor- und Betriebsdaten über einen Zeitraum von 18 Monaten der Versuchslinie verwendet. Der Datensatz umfasste neben den Auslegungsdaten die in Tabelle 1 dargestellten Parameter.

Es wurde eine zusätzliche Sonde für die Messung der NH₄-N-Konzentration im Zulauf installiert. Die gemessenen Daten dienten zu Beginn als zusätzliche Informationen für die Optimierung. Im weiteren Verlauf wurden die Daten in die Prognosemodellierung eingebunden. Für die Modellierung der Ablaufkonzentrationen wurde der Datensatz auf Plausibilität geprüft. Wertebereichsverletzung, Verbindungsausfälle, eingefrorene Werte und Sensor-Drifts wurden gefiltert. Auf Basis der gefilterten Daten wurden über 1.000 Modelle (KNN) trainiert und anhand des MAE („mean absolute error“) und des RSQ („Person's Produkt-Moment-Korrelation“) validiert. Für den Einsatz wurden die Prognosemodelle für NH₄-N, NO₃-N sowie PO₄-P mit den besten Validierungsergebnissen ausgewählt. [7]

Tabelle 1. Zusammenstellung der Parameter und deren zeitliche Auflösung, die zum Trainieren der KNN verwendet wurden

Parameter	Auflösung	Einheit
Zulauf- & Ablaufvolumenströme	15 Minuten Mittelwert	[l/s]
Trockensubstanzgehalt	15 Minuten Mittelwert	[g/l]
Abwassertemperatur Zulauf	15 Minuten Mittelwert	[°C]
Sauerstoffkonzentrationen in belüfteten Zone	15 Minuten Mittelwert	[mg/l]
Luftvolumenströme der Zonen 1-3	15 Minuten Mittelwert	[Nm ³ /h]
Ablaufkonzentration Ammonium [NH ₄ -N]	60 Minuten Mittelwert	[mg/l]
Ablaufkonzentration Nitrat [NO ₃ -N]	60 Minuten Mittelwert	[mg/l]
Ablaufkonzentration Ortho-Phosphat [PO ₄ -P]	60 Minuten Mittelwert	[mg/l]
Rezirkulation- & Rücklaufschlammmenge	15 Minuten Mittelwert	[l/s]
Überschusschlammmenge	24 Stunden Wert	[m ³ /d]
Zulaufkonzentration Ammonium [NH ₄ -N]	15 Minuten Mittelwert	[mg/l]
Fällmittelmenge	15 Minuten Mittelwert	[g/m ³ _{Abwasser}]

2.2 Modellaufbau

Der Aufbau der Modelle ist speziell auf den Einsatz für Prozesse im Wassersektor abgestimmt. Es handelt sich um eine sogenannte „Encoder-Decoder-Architektur“, deren innere Schichten aus rekurrenten neuronalen Netzen bestehen. Der Ansatz eignet sich besonders gut für eine modellbasierte Vorhersage von Zeitreihen. Bekannte physikalische oder chemische Zusammenhänge werden bereits während des Modelltrainings integriert. Solche als „physikinformierte neuronale Netze“ bezeichneten Modelle können Kausalitäten zwischen Prozessvariablen besser als herkömmliche Modelle darstellen.

Die relevanten Modellparameter unterteilt man in Eingangs- und Ausgangsvariablen. Eingangsvariablen setzen sich aus Störgrößen zusammen, die nicht verändert werden können (z.B. Zulauftemperatur oder Durchflussrate), sowie aus modifizierbaren Stellgrößen, die zur Prozesssteuerung genutzt werden (z. B. Belüftungsintensität). Ausgangsvariablen repräsentieren dagegen die Zielgrößen (z. B. NH₄-N Ablaufkonzentration), die durch das Modell prognostiziert werden sollen. Die Zielgrößen hängen in der Regel entscheidend mit den Optimierungszielen zusammen (z. B. sichere Einhaltung von Ablaufgrenzwerte/Schwellenwerte).

Aufgrund der Nachbildung der zugrundeliegenden realen Prozesse werden Modelle dieser Art häufig auch „digitale Zwillinge“ genannt. Mit deren Hilfe lassen sich komplexe Beziehungen zwischen Zulaufmengen, Durchflüssen, Temperaturen sowie Belüftungsprofilen und Abbauraten aufzeigen und sie ermöglichen präzise Vorhersagen künftiger Ablaufbedingungen.

Unter Einbindung der Echtzeitdaten und der Modellprognosen wertet ein genetischer Optimierer die bestmöglichen Stellgrößen (z. B. Sauerstoffkonzentration, Belüftungsintensität, Aktivierung oder Deaktivierung von belüfteten Volumina, Dosierung von Eisensulfat) aus. Dabei macht sich der Algorithmus die trainierten Modelle zunutze, um in Sekundenschnelle eine Vielzahl unterschiedlicher Szenarien für die jeweils kommenden Stunden durchzuspielen. Die zugrundeliegende Optimierungsstrategie zielt darauf ab, die variablen Stellgrößen so anzupassen, dass die Energieeffizienz gesteigert wird, ohne die festgelegten Schwellenwerte der Ablaufkonzentrationen zu überschreiten. Deshalb wurden für die Untersuchungen Ammonium- und Phosphorkonzentrationen jeweils als Zielwerte in der Optimierungsstrategie festgelegt.

2.3 Implementierung

Die Implementierung des Assistenzsystems erfolgte schrittweise. Im ersten Schritt wurde die Anwendung des Assistenzsystems manuell getestet. Dazu wurden die optimierten Stellgrößen

ßen, Prognoseinformationen und datenbasierte Fehlermeldungen (Verletzung der Grenzwerte, fehlende Messungen, Signalstörungen) durch ein Dashboard auf einem separaten Bildschirm dargestellt. Die Entwicklung des Dashboards wurde zusammen mit dem Betriebspersonal durchgeführt, um eine Umsetzung trotz des erhöhten Arbeitsaufwands zu ermöglichen. Die optimierten Stellgrößen wurden in einem 15-Minuten Intervall vorgeschlagen und durch das Betriebspersonal manuell übertragen. Im Fall von Störsituationen, nicht trainierten Lastfällen oder einer Wassertemperatur von $< 13^{\circ}\text{C}$ wurden vorher festgelegte Stellgrößen für die Soll-Sauerstoffkonzentration vorgegeben. Der spezifische Luftertrag und die Ablaufkonzentrationen der Versuchslinie wurden mit den Daten einer Referenzlinie verglichen.

3. Ergebnisse

Die 6-monatige Testphase ergab, dass entsprechend der vorliegenden Betriebssituation in ca. 82 % der Handlungsempfehlungen optimierte Stellgrößen vorgegeben wurden. Davon wurden ca. 61 % der Handlungsempfehlungen durch das Betriebspersonal übernommen.

In Abbildung 1 ist der abwasserspezifische Luftvolumenstrom in $\text{Nm}^3_{\text{Luft}}/\text{m}^3_{\text{Abwasser}}$ als Zeitreihe in Belebungsbecken 2 (BB2) mit umgesetzten Stellgrößen und in Belebungsbecken 3 (BB3) als Referenz vom 01.04.23 bis zum 01.10.23 dargestellt. Zusätzlich ist der vorgeschlagene abwasserspezifische Luftvolumenstrom bei durchgängiger Umsetzung (BB2_opt) sowie der durchschnittliche Abwasservolumenstrom (BB_mittel) aller Belebungsbecken dargestellt. Die Umsetzung der optimierten Stellgrößen führte zu einem reduzierten Luftverbrauch von ca. 10 %. Eine geplante zukünftige automatisierte Umsetzung würde zu einer größeren Reduzierung führen, wobei bisher keine Aussage zu dem Einfluss auf die Abwasserbehandlung getroffen werden kann.




Abbildung 1. Abwasserspezifischer Luftvolumenstrom in BB 2 (Versuchslinie) und BB 3 (Referenzlinie) vom 01.04.23 bis zum 01.10.2023

Gleichzeitig wurde eine Erhöhung der Ammoniumkonzentration ($\text{NH}_4\text{-N}$) im Ablauf der Versuchslinie ($\text{BB2}=2,2 \text{ mg/l}$) im Vergleich zur Vergleichslinie ($\text{BB3}=1,6 \text{ mg/l}$) um $0,6 \text{ mg/l}$ festgestellt. In Abbildung 2 ist der Verlauf der Ammoniumkonzentration im Ablauf von Belebungsbecken 2 mit optimierten Stellgrößen (BB2) und Belebungsbecken 3 (BB3) als Referenz vom 01.04.23 bis zum 01.10.23 dargestellt. Die Ablaufkonzentration der beiden Prozesslinien ist vergleichbar, da sie mit demselben Abwasser beaufschlagt wurden und die verfahrenstechnischen Parameter identisch sind. Während der Versuchsphase wurde die Abwasserbeaufschlagung in der Versuchs- und Vergleichslinie teilweise um 10 % erhöht.




Abbildung 2. Ammoniumkonzentration im Ablauf von BB2 (Versuchslinie) und BB3 (Referenzlinie) vom 01.04.23 bis zum 01.10.2023

4. Fazit

In der Pilotphase konnte beobachtet werden, dass die Handlungsempfehlungen eine präzise frachtbasierte Belüftungssteuerung ermöglichen. Auch Regenereignisse erkannte das Assistenzsystem frühzeitig, wodurch rechtzeitig, entsprechend des eintretenden Frachtstosses, die Belüftung erhöht und anschließend wieder herabgesetzt wurde. Die vom Betriebspersonal umgesetzten Handlungsempfehlungen führten zu einem reduzierten Luftverbrauch von ca. 10 %, während die Abwasserbeaufschlagung in Versuchs- und Referenzlinie teilweise um 10 % erhöht wurden. Obwohl die Ablaufkonzentration in dem Betrachtungszeitraum in der Versuchslinie sich leicht erhöhte, wird ein vergleichbares Optimierungspotenzial durch eine automatisierte Umsetzung der optimierten Stellgrößen erwartet. Hervorzuheben ist die Robustheit des Assistenzsystems besonders auch in Bezug auf Sensor- oder Signalstörungen. Kürzere Ausfälle der Eingangsgrößen werden im Optimierungssystem automatisch korrigiert bzw. falls möglich interpoliert.

Auf Grundlage der positiven Ergebnisse wurde sich daher für eine automatisierte Umsetzung des Assistenzsystems entschieden, um eine höhere Umsetzungsrate in Bezug auf die Ablaufqualität zu untersuchen. In diesem Zug wurde das Assistenzsystem hinsichtlich einer stärkeren Priorisierung der Reinigungsleistung kalibriert. Zusätzlich wurde eine direkte Steuerung der Soll-Luftmengen implementiert, die basierend auf den Modellprognosen im 10 Minutentakt berechnet wird. Gleichzeitig wurde das Assistenzsystem um eine Optimierung der Fällmitteldosierung für die chemische Phosphorelimination erweitert. Ähnlich wie bei der Berechnung der optimierten Stellgrößen für den Soll-Luftvolumenstrom sollen optimierte Fällmittelmengen basierend auf dem $\text{PO}_4\text{-P}$ -Prognosemodell durch den genetischen Algorithmus berechnet werden. Das Optimierungspotenzial für die automatisierte Umsetzung des Assistenzsystems wird derzeit in einer weiteren Pilotphase untersucht.

Data availability statement

Alle öffentlich verfügbaren Daten wurden im Artikel präsentiert. Zusätzliche Daten können aus Vertraulichkeitsgründen nicht veröffentlicht werden. Der entsprechende Autor kann kontaktiert werden, wenn zusätzliche Daten angefordert werden.

Author contributions

Die vorgestellten Ergebnisse sind das Resultat interner Zusammenarbeit zwischen Mitarbeiter:innen der Berliner Wasserbetriebe und Xylem. Der Artikel wurde verfasst, um die gewonnenen Erkenntnisse so zu vermitteln, dass sie in praktischen Anwendungen genutzt werden können.

Competing interests

Alle Autoren erklären, dass kein Interessenkonflikt besteht.

Funding

Das Projekt wurde durch eigene Ressourcen der Berliner Wasserbetriebe finanziert.

Acknowledgement

Wir bedanken uns bei der Unterstützung aller mitwirkenden Mitarbeiter:innen des Klärwerks Münchehofe und Schönerlinde, wodurch wir das Optimierungspotential des Assistenzsystems untersuchen konnten.

References

- [1] Sahlmann C., Libra J.A., Schuchardt A., Wiesmann U., and R. Gnirß, Eds., *A control strategy for reducing aeration costs during low loading periods*, 2003.
- [2] DWA, *Merkblatt DWA-M 209: Messung der Sauerstoffzufuhr von Belüftungseinrichtungen in Belebungsanlagen in Reinwasser und in belebtem Schlamm*, 2007th ed. Hennef: DWA, 2007.
- [3] DWA, *Arbeitsblatt DWA-A 216: Energiecheck und Energieanalyse - Instrumente zur Energieoptimierung von Abwasseranlagen*, 2015th ed. Hennef: Deutsche Vereinigung für Wasserwirtschaft, Abwasser und Abfall, 2022.
- [4] K. Walter and S. Troutman, "How to Solve Operational Challenges Using Data Driven Modeling and Optimization," in *Proceedings of the Water Environment Federation*, 2024.
- [5] A. M. Roohi, S. Nazif, and P. Ramazi, "Tackling data challenges in forecasting effluent characteristics of wastewater treatment plants," *Journal of environmental management*, vol. 354, p. 120324, 2024, doi: [10.1016/j.jenvman.2024.120324](https://doi.org/10.1016/j.jenvman.2024.120324).
- [6] BWB, *Wasserwissen*. [Online]. Available: <https://www.bwb.de/de/wasserwissen.php> (accessed: Feb. 1 2025).
- [7] Xylem, Ed., "Interne Projektspezifikation Projekt ANNA," 2024.