



Online Messung prozessrelevanter Zulaufdaten der KA Rospe zur Vorhersage des CSB mittels Methoden des Machine Learning

Kern, P.¹; Wolf, C.¹; Trauer, O.¹; Bongards, M.¹

¹ Fachhochschule Köln, Campus Gummersbach, Institut für Automation & Industrial IT, Steinmüllerallee 1, 51643 Gummersbach

Abstract

The measurement of the chemical oxygen demand (COD) in the inflow of wastewater treatment plants is important for the optimisation and control of the degradation processes of nitrification and denitrification. Until now, the measurement of the COD is very time consuming and cost-intensive until now, because 24-hour composite samples must be analysed in the laboratory by wet chemical analysis.

Online measurement technology in the form of spectroscopic measurement (10,000 – 20,000 €) or wet-chemical online analysers ($\geq 50,000$ €) is prohibitively expensive for small and medium-sized wastewater treatment plants. An extremely cost-effective alternative is the soft sensor described in this article. The sensor is used for measurement of

COD in the inlet of wastewater treatment plants, and can determine the current COD concentration based on standard measurement technology in the supply of small and medium-sized municipal wastewater treatment plants. Additionally, this soft sensor includes online measurement techniques for turbidity as well as ammonium and nitrate nitrogen ($\text{NH}_4\text{-N}$, $\text{NO}_3\text{-N}$). Regression methods from the area of machine learning are used for the development of the soft sensor. The results of a development and test phase at the wastewater treatment plant Rospe (Gummersbach) show that the values of the soft sensor match very well with the original data. The correlation values when compared to COD measurements lie in the regression with support vector regression at 0.98 with a RSME of 2.45 mg/l.

Kurzdarstellung

Die Messung des Chemischen Sauerstoffbedarfs (CSB) im Zulauf von Kläranlagen ist von zentraler Bedeutung für die Optimierung und Regelung der Abbauprozesse der Nitrifikation und Denitrifikation. Allerdings ist die Messung des CSB bislang sehr zeitaufwändig und kostenintensiv, da 24-Stunden Mischproben im Labor nasschemisch analysiert werden müssen.

Online-Messtechnik in Form von spektroskopischen Messgeräten (10.000 – 20.000 €) oder nasschemischen Online-Analysatoren (> = 50.000 €) sind insbesondere für kleine und mittlere Kläranlagen aus Kostengründen keine Alternative.

Eine extrem kostengünstige Alternative ist der im Folgenden beschriebene Softsensor für CSB im Kläranlagenzulauf, der auf Basis von Standardmesstechnik im Zulauf von kleinen und mittleren kommunalen Kläranlagen sowie mit zusätzlicher Online-Messtechnik für Trübung sowie Ammonium- und Nitratstickstoff ($\text{NH}_4\text{-N}$ und $\text{NO}_3\text{-N}$) die aktuelle CSB-Konzentration bestimmt. Zur Entwicklung des Softsensors werden Regressionsmethoden aus dem Bereich des Machine Learning eingesetzt. Die Ergebnisse einer Entwicklungs- und Testphase an der Kläranlage Rospe in Gummersbach zeigen, dass die Werte des Softsensors sehr gut mit den Originaldaten übereinstimmen. Die Korrelationswerte beim Vergleich mit CSB-Messungen liegen bei der Regression mit Support Vector Regression bei 0,98 mit einem RSME von 2,45 mg/l.

1 Einführung

Für die optimale Regelung, Optimierung und Simulation von Kläranlagen spielt der biochemische Zustand des Abwassers eine entscheidende Rolle, der durch verschiedene Faktoren wie Ammoniumstickstoff ($\text{NH}_4\text{-N}$), Konzentration des chemischen Sauerstoffbedarfs (CSB), etc. beschrieben wird (Reichl 2006).

Dieser Zustand ist messtechnisch jedoch nur unvollständig online erfassbar. Die Online-Messung

des CSB im Zulauf einer Kläranlage ist aufgrund von hohem Zeit- und Kostenaufwand nicht wirtschaftlich. Existierende Online-Messtechnik in Form von UV/vis spektroskopischen Sonden und nasschemischen Analysatoren erlauben bereits eine zuverlässige online CSB-Bestimmung, sind aber vor allem für kleine und mittlere Kläranlagen zu teuer.

Der CSB ist für die Optimierung und energieeffiziente Regelung von kleinen und mittleren Kläranlagen von entscheidender Bedeutung, da die Nitrifikation und Denitrifikation vorausschauend gefahren werden können und oftmals ein hohes Optimierungspotenzial vorhanden ist.

Um auch kleinen und mittleren Kläranlagen eine wirtschaftliche Lösung zur Online-Messung des CSB zu bieten, wird ein Softsensor für eine CSB-Zulaufmessung entwickelt.

In Zusammenarbeit mit dem lokalen Abwasserverband „Der Aggerverband“ und dem Messgerätehersteller „Endress & Hauser (E&H)“ wurde die kommunale Kläranlage Rospe mit innovativer Online-Messtechnik im Zulauf ausgestattet, um zu überprüfen, ob eine Berechnung des CSB über Standardmessgrößen möglich ist.

Auf Basis der Online-Messwerte wird mit Hilfe von mathematischen Regressionsverfahren aus dem Bereich des Machine Learning ein Softsensor für CSB entwickelt.

Die Datenaufnahme erfolgt im Zulauf der Kläranlage, der Kläranlage selber sowie im Ablauf der Anlage. Die hierbei gewonnenen Werte werden nachfolgend miteinander verglichen.

Es folgt zunächst ein kurzer Überblick über die eingesetzte Messtechnik, deren Messverfahren sowie deren Installation auf der KA Rospe. Im Anschluss werden die Datenaufbereitung und die verwendeten Regressionsmethoden erläutert, bevor detailliert auf die erzielten Ergebnisse eingegangen wird. Abschließend werden mögliche nächste Schritte aufgezählt.

<http://www.aggerverband.de>

<http://www.de.endress.com/>

2 Messtechnik und Analysemethoden

Die Kläranlage Rospe befindet sich in Nordrhein-Westfalen, etwa 50 Kilometer östlich von Köln in Gummersbach, direkt am Rospebach. Zurzeit sind 18.000 von maximal 34.000 Haushalten im Einzugsgebiet der KA Rospe angeschlossen. Im Ablauf der KA Rospe müssen die in Tabelle 1 dargestellten Grenzwerte eingehalten werden.

Tabelle 1: Ablaufgrenzwerte der KA Rospe.

Parameter	CSB	NH ₄ -N	N _{Ges}	P _{Ges}
in [mg/l]	60	8	18	2

2.1 Verwendete Online-Messtechnik

Im Zulauf des Vorklärbeckens und im Ablauf des Belebungsbeckens der KA Rospe waren im Versuchszeitraum vom 17.11.2012 – 15.12.2012 die folgenden Online-Messgeräte im Einsatz.

Messgeräte im **Zulauf** :

- 1) ISEmax CAS40D (E&H)
ionenselektive NH₄-N Sonde
- 2) TriOS ProPS (TriOS)
spektrometrische CSB-Sonde; 190 - 360 nm
- 3) Turbimax CUS51D (E&H)
Trübungs-Messung
- 4) STIP-scan CAS74 (E&H)
spektrometrische CSB-Sonde; 200 - 680 nm

Abbildung 1 zeigt die o.g. Online-Messgeräte, ergänzend zu diesen wurde Messtechnik des Aggerverbandes für Durchfluss, Leitfähigkeit und pH eingesetzt.

Im **Ablauf** der KA Rospe wurde ebenfalls Messtechnik des Aggerverbandes für NH₄-N und NO₃-N verwendet.

2.2 Datenübersicht

Die zugehörigen Messgrößen sind in Tabelle 2 festgehalten. Die kursiv dargestellten Daten wurden nicht für die Datenanalyse herangezogen, da sie

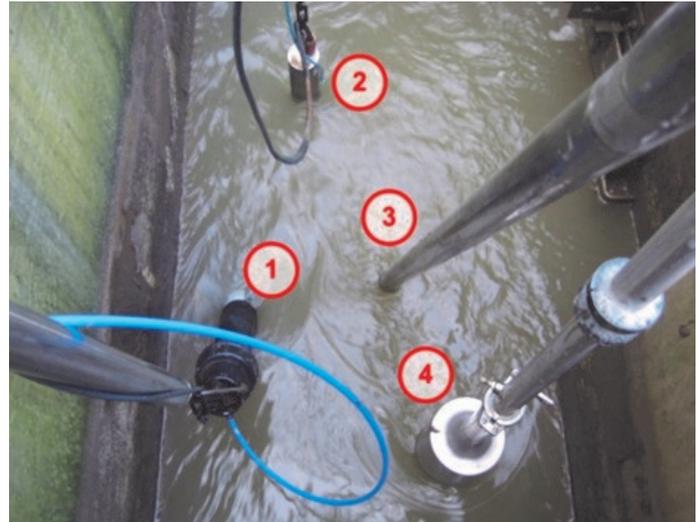


Abbildung 1: Online-Messtechnik im Zulauf der KA Rospe.

zum einen bekanntermaßen stark mit dem CSB korrelieren und zudem im Vergleich zu konventionellen Zulaufmessgeräten verhältnismäßig teuer sind und zum anderen im Ablauf der KA Rospe messen, was für eine rechnerische Bestimmung der Zulaufwerte meist mit zu hoher zeitlicher Verzögerung die erforderlichen Messwerte liefert.

Weiterhin handelt es sich hier teilweise um Geräte, die nicht zur Standard-Ausstattung von Anlagen gehören und deren Einsatz somit die allgemeine Übertragbarkeit der hier entwickelten Lösung gefährdet.

Im nächsten Abschnitt wird insbesondere auf die Datenvorverarbeitung der Messdaten sowie auf die verwendeten Regressionsmethoden eingegangen.

Tabelle 2: Übersicht der gemessenen Kenngrößen.

	Messtechnik	Kenngrößen
Zulauf	E&H	NH ₄ -N, NO ₃ -N, CSB, FNU (Formazine Nephelometric Units), pH-Wert, <i>SAK254, SAK433, Verschmutzungsgrad</i>
	Aggerverband	Durchflussmessung (Q), Leitfähigkeit (LF), Abwassertemperatur (T _{Abw}), pH-Wert
Ablauf	Aggerverband	NH ₄ -N, NO ₃ -N, O ₂ , Trockensubstanzgehalt (TS)

2.3 Datenvorverarbeitung

Die Messdaten der Geräte des Aggerverbandes werden in einem dreiminütigen Intervall aufgezeichnet. Die eigenen Messungen im Zulauf, welche in einem ein- bzw. zweiminütigen Intervall (nur $\text{NO}_3\text{-N}$) aufgezeichnet wurden, sind somit zur besseren Vergleichbarkeit auch auf ein dreiminütiges Intervall zu interpolieren. Durch die Verwendung des Timeseries-Tools (tstool) von MATLAB® (Mathworks 2012) wurden die Daten auf eben dieses Drei-Minuten-Intervall umgerechnet.

Anschließend wurden alle Daten 10-fach mit dem gleitenden Mittelwert geglättet, um Messrauschen und extreme Ausreißer weitestgehend zu minimieren.

Des Weiteren wurden die Daten zwischen 0 und 1 skaliert, so dass sich die Daten entsprechend analysieren und auswerten lassen. Insgesamt wurden vier unterschiedliche Datensätze – bestehend aus Trainings- und Validierungsdaten – untersucht.

Tabelle 3: Zur Regressionsanalyse verwendete Datensätze.

Datensatz	Messgrößen
st Zulauf	Q [l/S] Lf [$\mu\text{S}/\text{cm}$] T_{Abw} [°C] pH Trübung [FNU] CSB [mg/l]
+ NH_4	Zusätzliches $\text{NH}_4\text{-N}$ [mg/l]
+ NO_3	Zusätzliches $\text{NO}_3\text{-N}$ [mg/l]
+ NH_4 & NO_3	Zusätzliches $\text{NH}_4\text{-N}$ und $\text{NO}_3\text{-N}$

2.4 Mathematische Analyseverfahren

Für die Entwicklung des CSB Softsensors wurden folgende mathematische Regressionsverfahren verwendet: Multivariate Lineare Regression (MLR), Multivariate Normale Regression (MNR), Least-Squares Regression (LSR) und Support Vector Regression (SVR).

Um die unterschiedlichen Regressionsverfahren zu vergleichen, wird die Korrelation zwischen vorher-

gesagtem und gemessenem CSB bestimmt. Darüber hinaus wird der **Root Mean Square Error** (RMSE) sowie der **Root Mean Square Percentage Error** (RMSPE) bestimmt. Im Folgenden werden die Multivariate lineare Regression und die Support Vector Regression kurz vorgestellt. Die MLR repräsentiert hier die Standardregressionsverfahren, die alle eine ähnliche Funktionsweise besitzen und die SVR ist eine der am häufigsten verwendeten innovativen Regressionsverfahren, da sie sich besonders gut für die Abbildung nicht-linearer Datenmodelle eignet.

Multivariates lineares Regressionsmodell

Mit dem multivariaten linearen Regressionsmodell werden Beziehungen zwischen einer zu erklärenden oder abhängigen Variablen und einer oder mehreren erklärenden oder unabhängigen Variablen, den Regressoren, beschrieben (Hackl 2008).

Werden die Regressoren zur Vorhersage einer zu erklärenden oder abhängigen Variablen genutzt, so können diese als Prädiktoren bezeichnet werden. Sowohl die Prädiktoren als auch das zu vorhersagende Kriterium müssen intervall-skaliert sein (Wirtz & Nachtigall 2012).

Support Vector Regression

Die Support Vector Regression identifiziert den mathematischen Zusammenhang zwischen Eingangs- und Ausgangsdaten auf der Basis von Trainingsdaten. Man geht hierbei davon aus, dass dieser Zusammenhang nach Transformation der Daten in einem hyperdimensionalen Raum durch eine sogenannte Hypergerade abgebildet werden kann. Wie aus der analytischen Geometrie bekannt, wird diese Hypergerade durch sogenannte Stütz- und Richtungsvektoren, die „Support Vektoren“ beschrieben. Der Vorteil dieser mathematischen Methode ist, dass die Support Vector Regression spezielle Verfahren zur Vermeidung des „overfittings“ beinhaltet, was für selbstlernende Verfahren häufig ein Problem darstellt (Cristianini & Shawe-Taylor 2000).

3 Ergebnisse und Diskussion

Für die Regressionsanalyse wurden die vorhandenen vier Datensätze (Tabelle 3) jeweils in Trainings- und Validierungsdaten aufgeteilt. Die Trainingsdaten dienen dabei der Erstellung des mathematischen Regressionsmodells und die Validierungsdaten der Überprüfung anhand von, dem Modell bislang unbekanntem, Daten. Die Trainingsdaten bestehen aus 8.854 und die Validierungsdaten aus 4.027 Datenpunkten, entsprechend 27 Tagen und 23 Stunden. In den folgenden Unterkapiteln werden zunächst die Ergebnisse der Regressionsverfahren für die vier Datensätze vorgestellt, bevor anschließend eine vergleichende Bewertung erfolgt.

3.1 Ergebnisse für den Datensatz „st Zulauf“

Die Ergebnisse für den Datensatz „st Zulauf“ sind von besonderem Interesse, da in diesem Fall nur Messgrößen zur Prädiktion verwendet werden, die auf den meisten KA standardmäßig gemessen werden. Eine Ausnahme ist lediglich die Online-Messung der Trübung, die jedoch kostengünstig nachgerüstet werden kann.

Die in den Abbildungen 2 bis 5 dargestellten Ergebnisse zeigen deutlich, dass nicht nur bei den Trainingsdaten, sondern auch bei den Validierungsdaten eine gute bis sehr gute Übereinstimmung der Kurvenverläufe feststellbar ist. Dabei liefern die Standardregressionsverfahren MLR, MNR und LSR gleich gute Ergebnisse mit einem RMSE von 4,98 und einer Korrelation von 0,88 auf die Validierungsdaten. Im Vergleich dazu bildet die SVR den Kurvenverlauf der Validierungsdaten deutlich präziser ab (RMSE= 3,67 und Korrelation= 0.94).

Auffällig ist, dass alle Regressionsverfahren bei den Trainingsdaten Konzentrationsspitzen prädiktiert, die so nicht in den Originaldaten zu finden sind. Hinzu kommt, dass dieses Phänomen bei den Validierungsdaten nicht auftritt. Eine konkrete Ursache für diese extremen CSB Spitzen bei den Trainingsdaten konnte jedoch bislang nicht ausgemacht werden.

Insgesamt ist festzuhalten, dass bereits auf Basis der Standardmesstechnik im Zulauf der KA ein gut

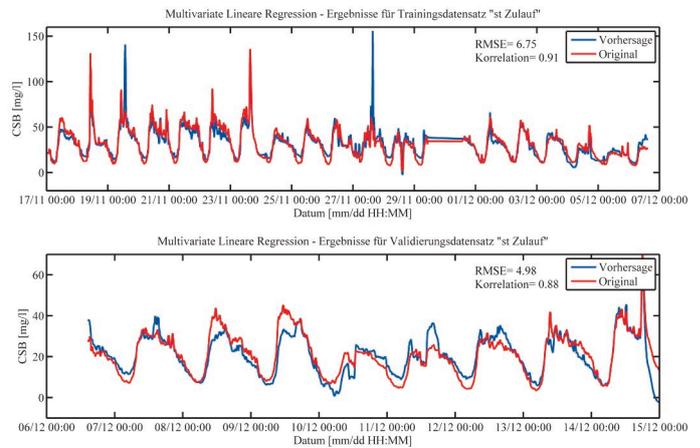


Abbildung 2: Ergebnisse der multivariaten linearen Regression für Trainings- und Validierungsdaten des Datensatzes „st Zulauf“.

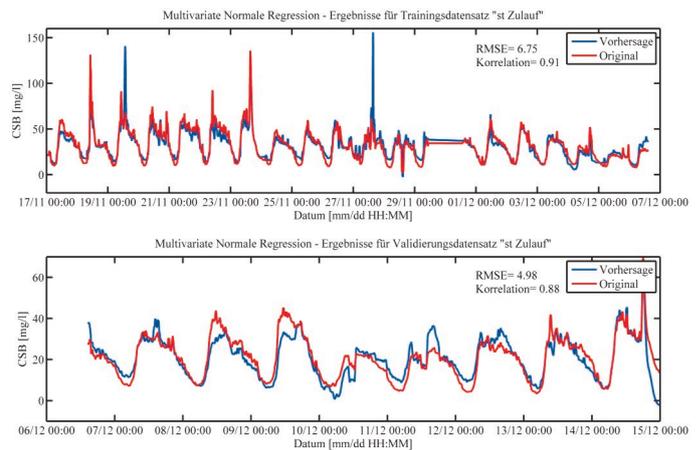


Abbildung 3: Ergebnisse der multivariaten normalen Regression für Trainings- und Validierungsdaten des Datensatzes „st Zulauf“.

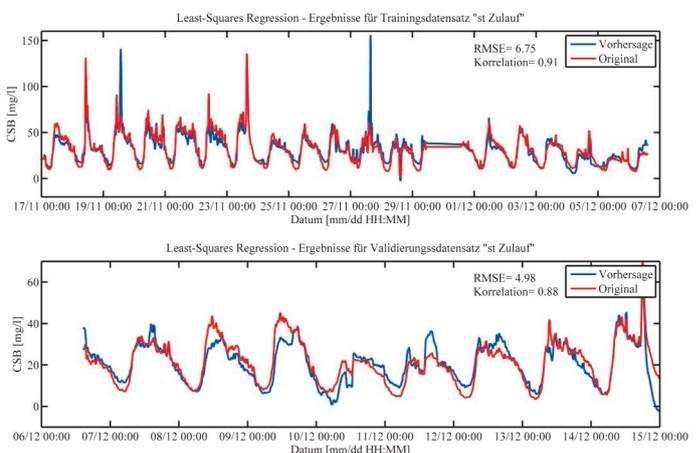


Abbildung 4: Ergebnisse der least-squares Regression für Trainings- und Validierungsdaten des Datensatzes „st Zulauf“.

funktionierender Softsensor für CSB entwickelt werden kann.

3.2 Ergebnisse für den Datensatz „+ NH₄“

Die Ergebnisse für der Datensatz „+ NH₄“ zeigen, dass durch Hinzunahme zusätzlicher Messgrößen eine weitere Verbesserung der Regressionsmodelle erreicht wird.

Insbesondere die NH₄-N Konzentration im Zulauf der KA Rospe erlaubt eine genauere Prädiktion des CSB, da beide Messgrößen einen ähnlichen Verlauf aufweisen.

Auch hier erzielt die SVR das beste Ergebnis mit einem sehr geringen RMSE von 2.50 und einer Korrelation von 0.97 im Vergleich zu RMSE= 3,52 und Korrelation= 0.94 für die Standardregressionsmethoden.

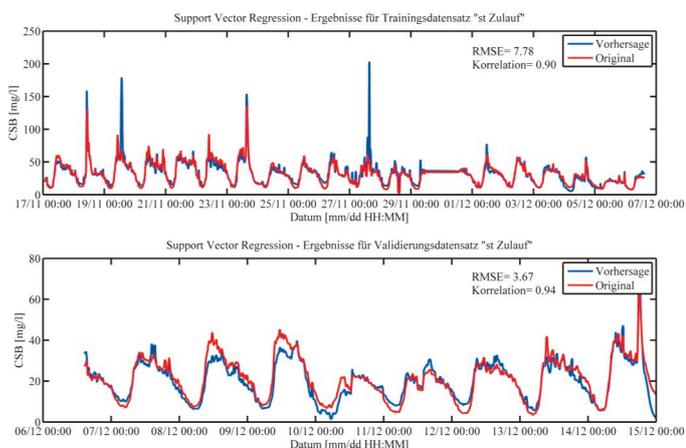


Abbildung 5: Ergebnisse der Support Vector Regression für Trainings- und Validierungsdaten des Datensatzes „st Zulauf“.

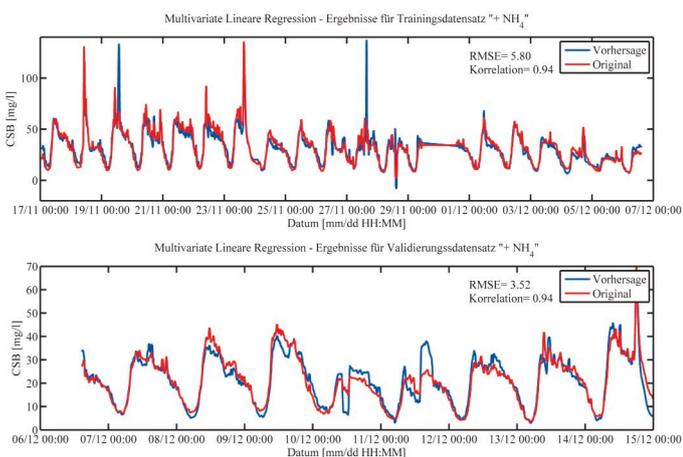


Abbildung 6: Ergebnisse der multivariaten linearen Regression für Trainings- und Validierungsdaten des Datensatzes „+ NH₄“.

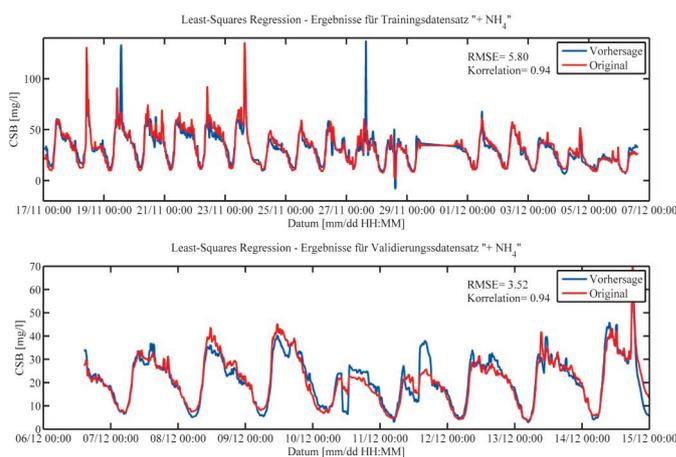


Abbildung 8: Ergebnisse der least-squares Regression für Trainings- und Validierungsdaten des Datensatzes „+ NH₄“.

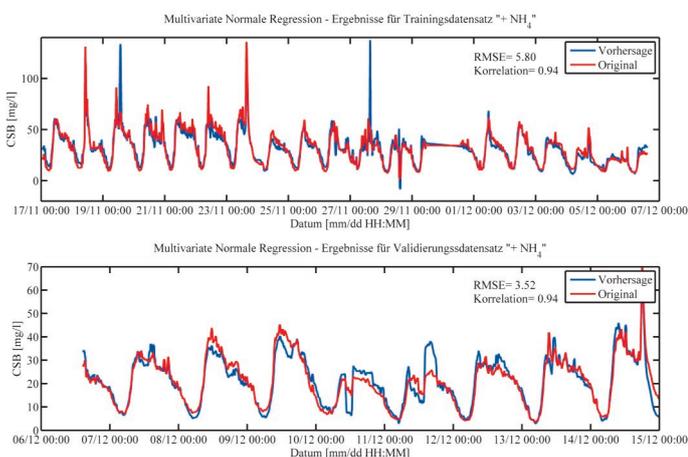


Abbildung 7: Ergebnisse der multivariaten normalen Regression für Trainings- und Validierungsdaten des Datensatzes „+ NH₄“.

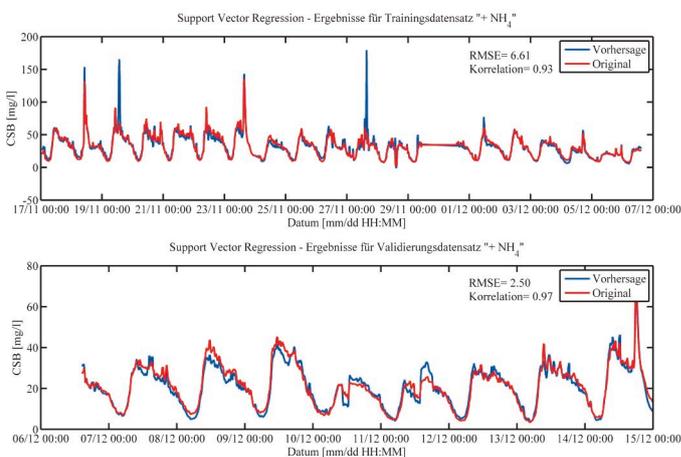


Abbildung 9: Ergebnisse der Support Vector Regression für Trainings- und Validierungsdaten des Datensatzes „+ NH₄“.

3.2 Ergebnisse für den Datensatz „+ NO₃“

Die Ergebnisse für den Datensatz „+ NO₃“ zeigen ebenfalls, dass eine gute Übereinstimmung zwischen Softsensor und Originaldaten erreicht werden kann.

Allerdings sind die Ergebnisse im Vergleich zum Datensatz „+ NH₄“ bei den Standardregressionsverfahren leicht schlechter, da bei den Validierungsdaten meist leicht erhöhte CSB Konzentrationen erreicht werden.

Wie bereits bei den zwei zuvor betrachteten Datensätzen ist die Genauigkeit der SVR mit einem

RMSE von 3,04 und einer Korrelation von 0,97 am besten, wenn auch hier geringfügig erhöhte CSB Konzentrationen berechnet werden.

Ein Blick auf die Wetterdaten der KA Rospe zeigt, dass am 10.12.2012, ein Zeitpunkt, ab dem die prä-diktieren Werte steigen, ein Wetterumschwung von Regenwetter auf Trockenwetter stattfand. Interessant ist, dass sich diese Wetteränderung lediglich auf die NO₃-N Konzentration im Zulauf auszuwirken scheint. Bei den vorherigen Datensätzen kann dieser Effekt kaum festgestellt werden.

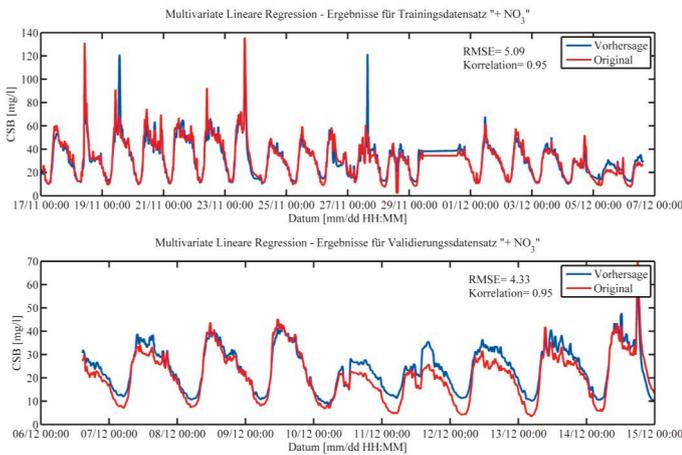


Abbildung 10: Ergebnisse der multivariaten linearen Regression für Trainings- und Validierungsdaten des Datensatzes „+ NO₃“.

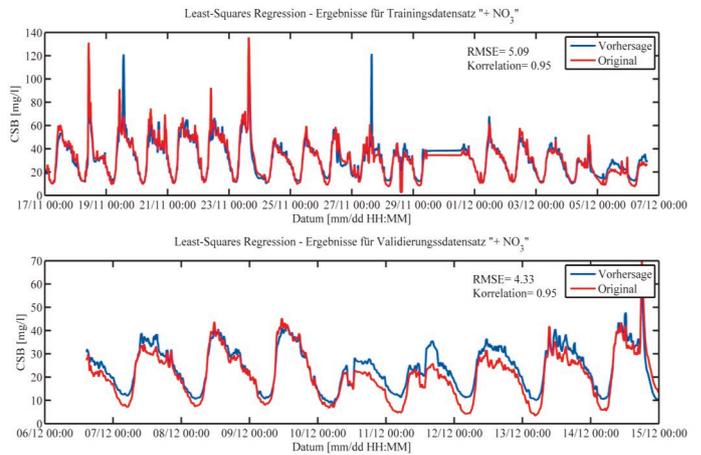


Abbildung 12: Ergebnisse der least-squares Regression für Trainings- und Validierungsdaten des Datensatzes „+ NO₃“.

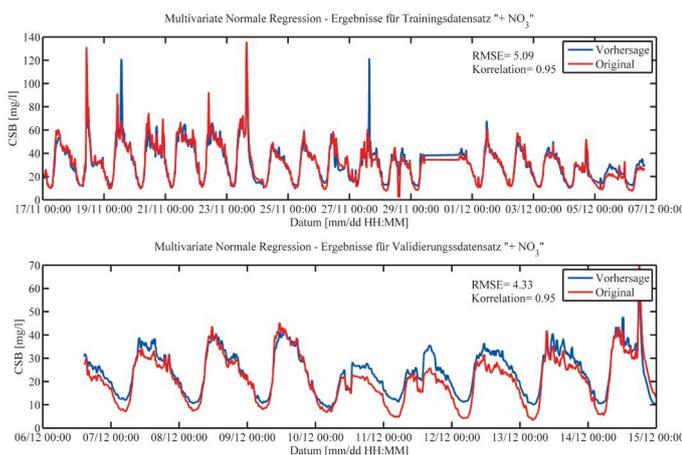


Abbildung 11: Ergebnisse der multivariaten normalen Regression für Trainings- und Validierungsdaten des Datensatzes „+ NO₃“.

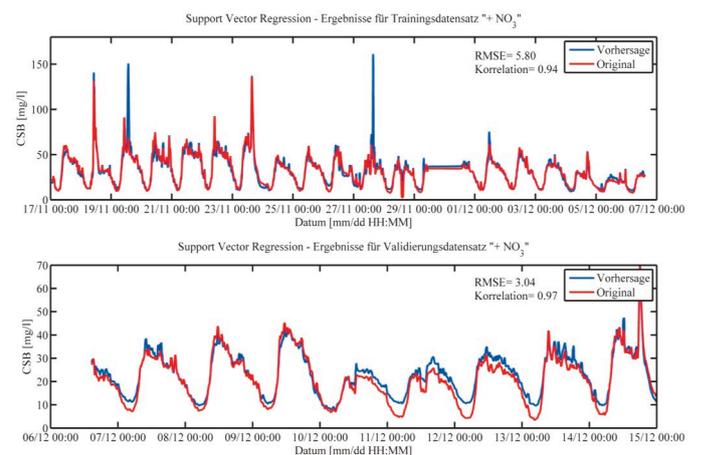


Abbildung 13: Ergebnisse der Support Vector Regression für Trainings- und Validierungsdaten des Datensatzes „+ NO₃“.

3.3 Ergebnisse für den Datensatz „+ NH₄ & NO₃“

Für die Standardregressionsverfahren sind die Ergebnisse für den Datensatz „+ NH₄ & NO₃“ mit ei-

nem RMSE von 3,81 leicht schlechter als für den Datensatz „+ NH₄“ mit einem RMSE von 3,50. Allerdings ist die Übereinstimmung der Kurvenverläufe

für den Datensatz „+ NH₄ & NO₃“ mit einer Korrelation von 0,97 gegenüber 0,94 besser. Eine deutliche Verbesserung der Prädiktionsgenauigkeit im Vergleich zu den vorhergehenden Daten-

sätzen zeigt die SVR mit einem sehr guten RMSE von 2,45 und einer nahezu perfekten Übereinstimmung der Kurvenverläufe mit einer Korrelation von 0,99.

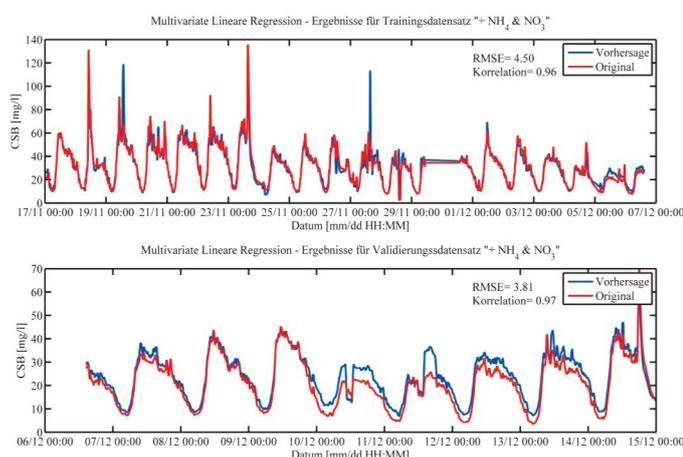


Abbildung 14: Ergebnisse der multivariaten linearen Regression für Trainings- und Validierungsdaten des Datensatzes „+NH₄ & NO₃“.

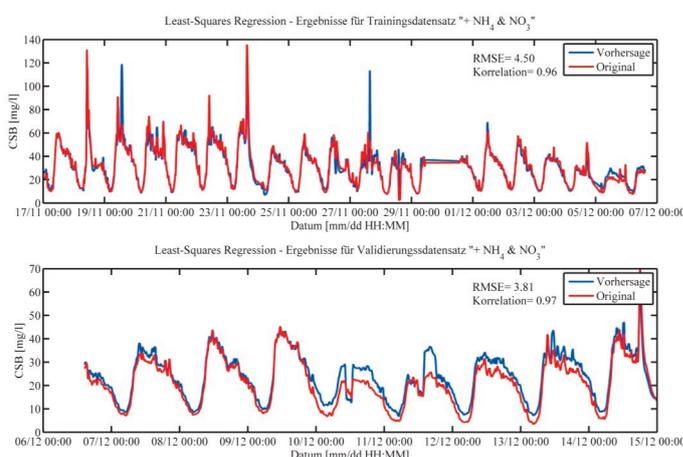


Abbildung 16: Ergebnisse der least-squares Regression für Trainings- und Validierungsdaten des Datensatzes „+NH₄ & NO₃“.

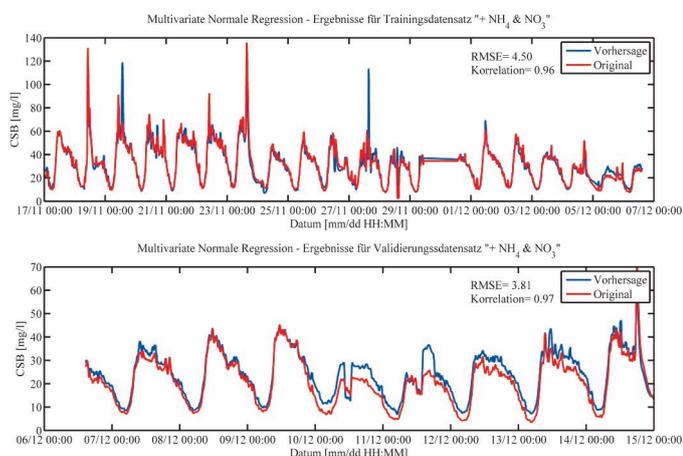


Abbildung 15: Ergebnisse der multivariaten normalen Regression für Trainings- und Validierungsdaten des Datensatzes „+NH₄ & NO₃“.

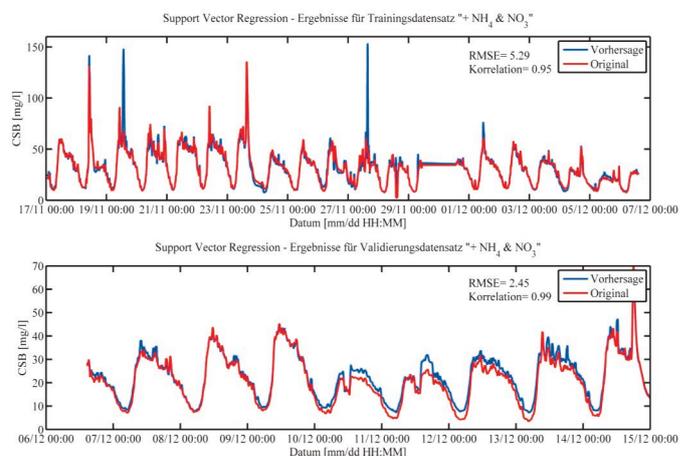


Abbildung 17: Ergebnisse der Support Vector Regression für Trainings- und Validierungsdaten des Datensatzes „+NH₄ & NO₃“.

3.4 Vergleich der Regressionsergebnisse

Für einen detaillierten Vergleich der Regressionsergebnisse werden im Folgenden die Fehlermaße RMSE und RMSPE sowie die Ergebnisse der Korrelationsanalyse dargestellt. Die Fehlermaße dienen dazu die Abweichungen des Softsensors von den Originaldaten zu quantifizieren.

Die Korrelationsanalyse erlaubt zudem eine Überprüfung der Signaldynamik. Ist die Korrelation nahe dem Wert 1, so besitzen die beiden miteinander verglichenen Signale den gleichen Verlauf, ist sie nahe 0, so sind die Signalverläufe vollständig verschieden.

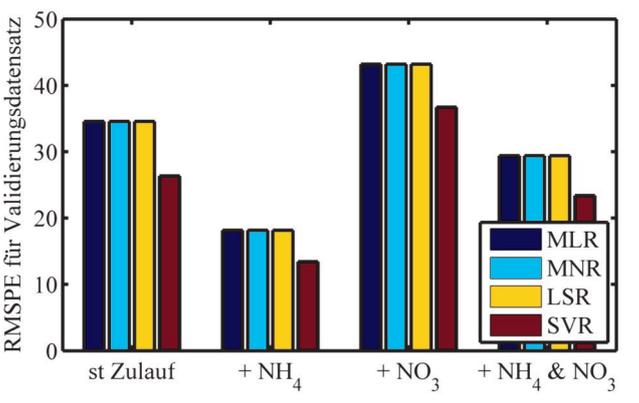
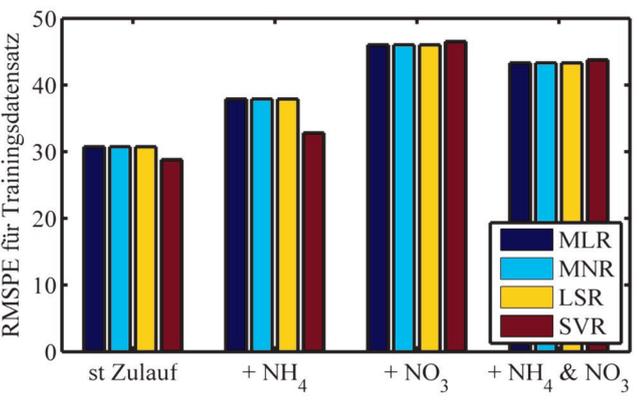
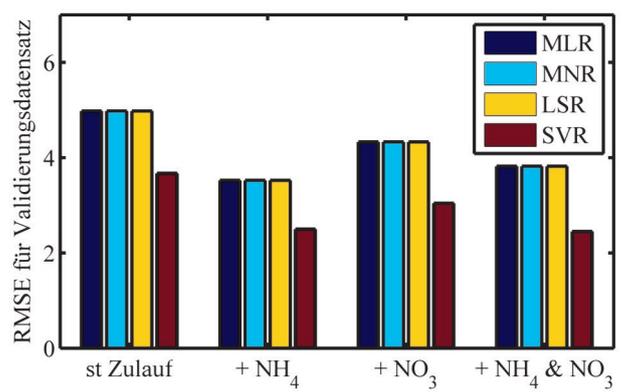
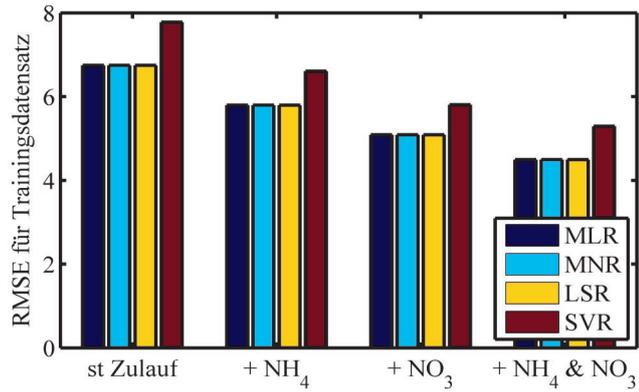


Abbildung 18: Fehler für die Prädiktion des Softsensors im Vergleich zu den Originaldaten.

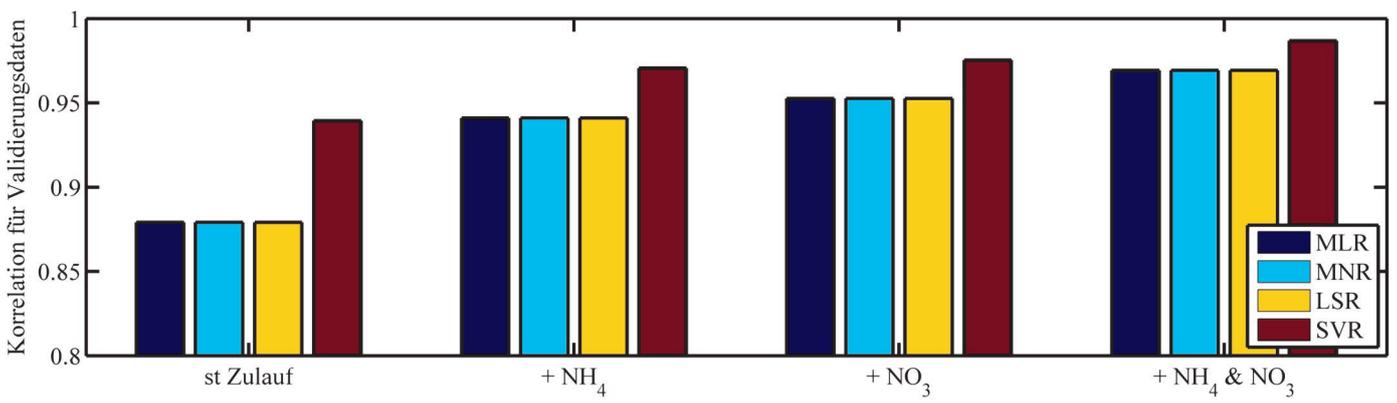
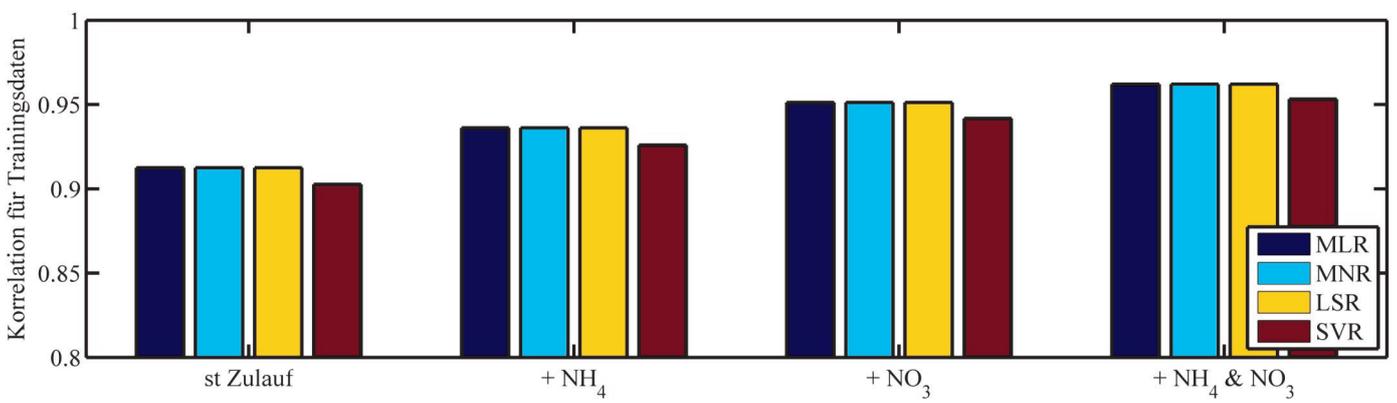


Abbildung 19: Korrelation der Prädiktion des Softsensors mit den Originaldaten.

Betrachtet man die Fehler der unterschiedlichen Regressionsverfahren auf die Trainings- und Validierungsdaten (Abb. 18), so sind die Fehler relativ gering. Somit ist festzustellen, dass für alle Verfahren eine sehr gute Übereinstimmung des Softsensors mit den Realdaten vorliegt.

Hierbei ist besonders hervorzuheben, dass sich die Standardregressionsverfahren in ihrer Prädiktionsqualität kaum unterscheiden, sondern nahezu die gleichen Ergebnisse liefern. Lediglich die SVR fällt hierbei aus dem Rahmen. Insbesondere die Tatsache, dass die SVR bei den Trainingsdaten schlechter abschneidet als die Standardverfahren, im Gegensatz dazu aber bei den Validierungsdaten deutlich bessere Ergebnisse liefert, sollte mit weiteren Messkampagnen untersucht werden.

Darüber hinaus lassen sich bei den Fehlermaßen deutliche Unterschiede bei der Prädiktionsqualität für die vier Datensätze ausmachen. So erzielen die Standardverfahren mit dem Datensatz „+ NH₄“ und die SVR mit dem Datensatz „+ NH₄ & NO₃“ die besten Ergebnisse. Insgesamt wird allerdings deutlich, dass die Unterschiede nicht gravierend sind und bereits mit dem ersten Datensatz „st Zulauf“ ausreichend gute Ergebnisse erzielt werden können.

Vergleicht man zusätzlich die Korrelation der Signalverläufe zwischen Softsensor und Originaldaten aus Abbildung 19, so wird deutlich, dass alle Verfahren für die vier Datensätze sehr gute und somit sehr hohe Korrelationswerte erreichen. Mit einer Korrelation zwischen 0,88 und 0,98 für die SVR und dem Datensatz „+ NH₄ & NO₃“ kann vor einer sehr guten Prädiktionsqualität des Softsensors gesprochen werden.

4 Zusammenfassung

In einem vierwöchigen Messzeitraum im November – Dezember 2012 auf der Kläranlage Rospe bei Gummersbach wurde ein Softsensor für CSB im Zulauf der KA entwickelt. Mit Hilfe der zusätzlich im Zulauf der KA Rospe installierten Messtechnik der Firma E&H sowie mit der hauseigenen Messtechnik des Aggerverbandes wurden die Daten im Zulauf aufgezeichnet und nach einer Datenaufbereitung in verschiedenen Regressionsverfahren genutzt.

Die erzielten Ergebnisse zeigen, dass die Nutzung eines Softsensors für CSB im Zulauf der KA Rospe nicht nur möglich ist, sondern gleichermaßen qualitativ hochwertige Prädiktionen für die CSB Konzentration im Zulauf erzielt werden können. Somit ist es möglich, eine softwarebasierte Alternative für die Messung der CSB-Konzentration basierend auf Standardmesstechnik im Zulauf von Kläranlagen zu entwickeln. Dies bietet vor allem für kleine und mittlere KA einen entscheidenden Vorteil, die aus Kostengründen keine spektroskopischen Sonden oder nasschemischen Analysatoren einsetzen können. Hinzu kommt, dass sich neue Vermarktungswege für solche Softsensoren ergeben, da sie als zusätzlicher Service in Verbindung mit neuer Messtechnik im KA Zulauf angeboten werden können. Diese ersten Ergebnisse sind jedoch noch weiter zu verifizieren. Zum einen ist ein Langzeittest des Softsensors auf der KA Rospe erforderlich, um dessen Zuverlässigkeit abschätzen zu können und um die Kalibrierintervalle für einen sicheren Betrieb festzulegen. Zum anderen muss die Entwicklung eines Softsensors und dessen Nachkalibrierung anhand aktueller KA Daten automatisiert werden. Die gewonnenen Ergebnisse zeigen, dass in diesem Bereich ein sehr hohes Potenzial vorkommt, dass es auszunutzen gilt.

Ein besonderer Dank gilt dem Aggerverband für die Unterstützung bei der Installation und Betreuung der Messgeräte sowie der Firma Endress&Hauser Conducta für die Bereitstellung der umfangreichen Messtechnik.

Referenzen

- Bischofsberger, W.D.N.; Rosenwinkel, K.H.; Seyfried C.F.; Böhnke, B. (2005): Anaerobtechnik, Heidelberg.
- Cristianini, N. & Shawe-Taylor, J. (2000): An introduction to support vector machines: And other kernel-based learning methods. Cambridge; New York: Cambridge University Press.
- Hackl, P. (2008): Einführung in die Ökonometrie, Pearson Studium, München.
- Mathworks, 2012. Übersicht: MATLAB. <http://www.mathworks.de/> (accessed 24 May 2013).
- Reichl, G. (2006): Optimierte Bewirtschaftung von Kläranlagen basierend auf der Modellierung mit Modelica, 1st ed, Cuvillier, Göttingen.
- Wirtz, M.A. & Nachtigall, C. (2012): Statistische Methoden für Psychologen, 6th ed, Beltz Juventa, Weinheim, Basel .