

Abb. 1 Eisenverockung am Übergabepunkt vom Brunnen zum Rohrnetz an einem Wasserwerk des OOWV



Datengestützte Prognosemodelle für die Leistungsfähigkeit von Förderbrunnen

Förderbrunnen unterliegen Alterungsprozessen, die zu einer Abnahme ihrer Leistungsfähigkeit und zu höheren Energiekosten führen. Um dies bei der Sanierungsplanung berücksichtigen zu können, wurden datengetriebene Brunnenalterungsmodelle entwickelt und getestet. Diese auf baulichen, betrieblichen und anderen Brunneneigenschaften basierenden Prognosemodelle ermöglichen eine genaue Vorhersage des Zustands der einzelnen Brunnen. Die Ergebnisse können für eine bedarfsgerechte und effiziente Brunnensanierungsplanung genutzt werden.

Alterungsprozesse wie Eisenverockerung, Biofouling oder Verkalkung können die Leistungsfähigkeit von Förderbrunnen erheblich einschränken. Mit fortschreitender Alterung der Brunnen verringert sich in der Regel deren spezifische Ergiebigkeit und erhöhen sich der Energiebedarf und die damit verbundenen Förderkosten. Je nach Ausmaß der

Alterung und Anzahl der betroffenen Brunnen kann es in der Folge auch zu Einschränkungen des Trinkwasserangebots im Versorgungsgebiet kommen.

Der Brunnenalterung und den negativen Auswirkungen kann mit geeigneten Rehabilitationsmaßnahmen entgegengewirkt werden. Dazu gehören z. B. mechanische und chemische Regenera-

tionsverfahren sowie der Brunnenneubau. Allerdings wird der Zustand eines Brunnens und damit sein Rehabilitationsbedarf nicht kontinuierlich gemessen und ist zudem von einer Vielzahl an Einflussfaktoren abhängig. Da diese multivariaten Zusammenhänge mit einfachen statistischen Methoden nur schwer abzubilden sind, werden Brun-




Abb. 2 Häufigkeitsverteilungen ausgewählter Variablen, bezogen auf die jeweils letzte Beobachtung der Brunnen in Betrieb

nenalterungsmodelle bei der operativen Planung bisher kaum eingesetzt.

Um die Ergiebigkeit eines Brunnens unter Berücksichtigung der verschiedenen Einflussfaktoren prognostizieren zu können, wurden verschiedene datengetriebene Modellansätze für die Brunnenalterung entwickelt und getestet. Die Modellansätze basieren auf regressionsanalytischen Verfahren und Methoden des Maschinellen Lernens und wurden für 279 Förderbrunnen des Oldenburgisch-Ostfriesischen Wasserverbands (OOWV) eingesetzt. Die Arbeiten basieren auf Vorarbeiten des Kompetenzzentrums Wasser Berlin (KWB) im Rahmen des EU-Projektes Digital Water City (DWC) [1] und wurden im Verbund von Fichtner Water & Transportation (FWT), Fichtner IT Consulting (FIT), dem OOWV und dem KWB durchgeführt. Im vorliegenden Manuskript werden die Modellergebnisse diskutiert und die Rolle verschiedener Einflussfaktoren für die Brunnenalterung bzw. den Ergiebigkeitsverlust untersucht.

Datengrundlage

Zunächst wurden Daten zum zeitlichen Verlauf der Ergiebigkeit der Brunnen und zu verschiedenen möglichen Einflussvariablen aus unterschiedlichen Quellsystemen zusammengetragen und aufbereitet (Abb. 2). Dazu gehören:

- Messdaten zur Ergiebigkeit der Brunnen aus Kurzpumpversuchen (als Maß für den Zustand und Zielgröße der Alterungsmodelle),
- bauliche Eigenschaften der Brunnen (z.B. Baujahr und Filtertiefe),
- Standorteigenschaften (z. B. Hydrogeologische Teilräume und Variation des Ruhewasserspiegels),
- betriebliche Eigenschaften (z. B. tägliche Brunnenlaufzeit und Anzahl der durchgeführten Regenerierungen),
- Wasserqualitätsparameter (z. B. Nitrat- und Eisenkonzentration).

Die Datenaufbereitung umfasste z. B. das Berechnen der relativen, brunnen-spezifischen Ergiebigkeit bezogen auf

den zuletzt beobachteten Höchstwert, das Entfernen von Ausreißern, die Füllung von Datenlücken, das Zusammenfassen seltener Merkmalsausprägungen sowie die bauwerkspezifische und zeitliche Verknüpfung der verschiedenen Datenquellen (z. B. Informationen zu den durchgeführten Regenerierungen und den Ergiebigkeitsmessungen).

Der bereinigte Datensatz umfasst insgesamt 3.422 Ergiebigkeitsmessdaten für 279 Brunnen aus 13 Wasserwerken, davon 194 in Betrieb und 85 stillgelegt. Die in Betrieb befindlichen Brunnen haben ein mittleres Alter von 38 Jahren, wobei der älteste Brunnen 66 Jahre alt ist. Je Brunnen gibt es im Durchschnitt zwölf Ergiebigkeitsmessungen (Abb. 3), wobei der Großteil (95 %) dieser Daten in den Jahren seit 1995 aufgezeichnet wurde.

Bedeutung der Einflussvariablen

Den Ergiebigkeitsmessungen der einzelnen Brunnen sind 38 verschiedene sta-




Abb. 3 Anzahl der Ergiebigkeitsmessungen je Brunnen

tische oder zeitabhängige Einflussvariablen zugeordnet. Stark voneinander abhängige Variablen können die Genauigkeit mathematischer Modelle negativ beeinflussen und sollten daher entfernt werden. Zu diesem Zweck wurden alle Einflussvariablen hinsichtlich ihrer Korrelationen untereinander paarweise untersucht. Für die numerischen Variablen wurde der Spearman-Rangkorrelationskoeffizient berechnet. Für die kategorischen Variablen wurde der Chi-Quadrat-Unabhängigkeitstest durchgeführt und daraus Cramér's V [2] als Maß für die Korrelation abgeleitet.


Sechs der 38 Einflussvariablen korrelieren mit mindestens einer anderen Variable vollständig (z. B. Wasserwerk mit hydrogeologischem Teilraum) und wurden daher aus dem Daten-

satz entfernt. Für die verbleibenden 32 Einflussvariablen wurde die Bedeutung für die relative Ergiebigkeit der Brunnen untersucht. Mit den Untersuchungen sollte zum einen das Daten- und Modellverständnis verbessert werden. Zum anderen sollten unbedeutende Variablen aus dem Datensatz entfernt werden.

Die Bedeutung der Variablen für die relative Ergiebigkeit der Brunnen wurde über einen Random-Forest-Modellansatz [3] und die Methode der Variablenpermutation [4] ermittelt. Dabei wird im ersten Schritt ein Prognosemodell aufgebaut und anhand von Testdaten hinsichtlich des Modellfehlers bewertet. Im zweiten Schritt werden die Werte der einzelnen Variablen durcheinander gewürfelt („permutiert“) und beurteilt, wie stark diese Permutation den Modellfehler, hier den mittleren quadratischen Fehler, erhöht. Je stärker sich die Variablenpermutation auf den Modellfehler auswirkt, desto größer ist die Bedeutung der jeweiligen Variable für die relative Ergiebigkeit.

Die größte Rolle für die Ergiebigkeit der Brunnen spielen nach dieser Methode das Brunnenalter, die Zeitspanne seit der letzten Regenerierung und die Anzahl der insgesamt durchgeführten Regenerierungen. Auch andere betriebliche Eigenschaften wie die durchschnittliche tägliche Brunnenlaufzeit sowie die Wasserqualität haben eine erhöhte Bedeutung für die Ergiebigkeit der Brunnen. Dagegen haben die baulichen und standortbezogenen Eigenschaften der Brunnen, wie z. B. das Filtermaterial oder die Anzahl der Nachbarbrunnen im Umkreis von einem Kilometer, – mit Ausnahme der Filtertiefe – eine untergeordnete Bedeutung (Abb. 4).

Bei einigen der Einflussvariablen lassen sich Verteilungsmuster in Bezug auf die relative Ergiebigkeit und das Brunnenalter erkennen, die auf zwei relevante Prozesse der Brun-



(gemessen an rel. Erhöhung des Fehlers (MSE), durch Verändern / Weglassen einer Variable)

Abb. 4 Bedeutung der Variablen für die relative Ergiebigkeit der Brunnen




Abb. 5 Häufigkeit relativer Ergiebigkeitswerte < und ≥ 80 % für Brunnenalter < und ≥ 40 Jahre, unterschieden nach brunnesspezifischer Nitratkonzentration (< / ≥ 1 mg/L; links) und pH-Werten (< / ≥ 7; rechts)

nenalterung hinweisen: die Eisenverockerung, begünstigt durch erhöhte Nitrat- bzw. Sauerstoffkonzentrationen, und die Verkalkung, begünstigt durch hohe pH-Werte und geologische Faktoren. Während der Prozess der Eisenverockerung vergleichsweise langsam und erst bei einem Brunnenalter von ≥ 40 Jahren deutlich erkennbar ist, kann sich die Verkalkung bereits bei jüngeren Brunnen negativ auf die Ergiebigkeit auswirken. Abbildung 5 zeigt die Verteilung der Ergiebigkeitswerte für unterschiedliche Nitratkonzentrationen und pH-Werte, jeweils für Brunnenalter < 40 und ≥ 40 Jahre.

Die identifizierten Treiber für die Eisenverockerung (hohe Nitrat- und Sauerstoffkonzentrationen) sind stark mit baulichen und betrieblichen Eigenschaften der Brunnen verknüpft. So tritt Nitrat, das in erster Linie über Sickerwasser aus landwirtschaftlich genutzten Flächen ins Grundwasser gelangt, vor allem bei Brunnen mit Filtertiefen < 40 m in erhöhten Konzentrationen auf. Erhöhte Sauerstoffkonzentrationen werden vor allem bei Brunnen mit variierenden täglichen Laufzeiten beobachtet. Auslöser für den Sauerstoffeintrag sind möglicherweise ein vorübergehendes Absinken des Betriebswasserspiegels sowie durch die Schaltung erzeugte Turbulenzen [5].

Untersuchte Brunnenalterungsmodelle

Für die Zustandsprognosen für die Brunnen des OOWV wurden sieben verschiedene Modellansätze getestet und hinsichtlich ihrer Genauigkeit bewertet. Dazu gehören multivariate Regressionsmethoden, baumbasierte Ensemble-Modelle und künstliche neuronale Netze. Beispielsweise ist im Folgenden der Gradient-Boosting-Ansatz, ein baumbasiertes Ensemble-Modell, erläutert, welches neben dem Random-Forest-Modell die höchste Genauigkeit bezüglich der Ergiebigkeitsprognosen aufweist.

Gradient Boosting [6] ist ein Algorithmus des Maschinellen Lernens, der zur Lösung von Regressions- und Klassifikationsaufgaben genutzt werden kann. Ein Gradient-Boosting-Modell besteht aus mehreren einfach strukturierten Entscheidungsbäumen (sogenannten „weak learners“), die zu einem Gesamt-Modell (Ensemble) kombiniert werden. Die einzelnen Entscheidungsbäume des Modells werden nacheinander aufgebaut und lernen jeweils aus den Fehlern ihrer Vorgänger.

Zuerst wird dabei ein Entscheidungsbaum auf die Daten trainiert, um die relative Ergiebigkeit vorherzusagen (Modell 1). Dann werden die Abweichungen zwischen den Vorhersagen und den tatsächlichen Beobachtungen berechnet und ein zweiter Entscheidungsbaum wird auf diese Abweichungen

trainiert (Modell 2). Die Vorhersagen aus Modell 1 und Modell 2 werden addiert, um korrigierte Vorhersagen zu erstellen. Für diese korrigierten Vorhersagen werden erneut die Abweichungen berechnet, ein weiterer Entscheidungsbaum wird darauf trainiert und für die Korrektur der bisherigen Vorhersagen genutzt. Dieser Prozess wird wiederholt, bis ein definiertes Abbruchkriterium erreicht ist. Aus der schrittweisen Kombination der Entscheidungsbäume resultiert ein leistungsstarkes Ensemblemodell. Der Algorithmus ist nicht nur vergleichsweise genau, sondern zeichnet sich auch durch geringe Trainings- und Prognosezeiten aus.

Alle Modelle wurden mit zufällig ausgewählten Trainingsdaten, bestehend aus 80 % der bereinigten Datensätze, aufge-

Modellansatz	Regressionsgüte			Klassifikationsgüte	
	r^2	RMSE	MAE	Trefferquote	Genauigkeit
Multiple Lineare Regression	0,38	13,7%	10,4%	70,1%	63,0%
Logistische Regression ¹	-	-	-	60,9%	71,0%
Cox Proportional Hazards ¹	-	-	-	49,4%	62,8%
MARS	0,57	11,4%	8,53%	79,2%	71,2%
Random Forest	0,81	7,65%	4,97%	86,3%	86,3%
Gradient Boosting	0,81	7,66%	5,08%	87,8%	84,4%
Neuronales Netz	0,75	8,64%	5,82%	82,2%	82,7%

¹ Reines Klassifikationsmodell

Tab. 1 Güteindikatoren für die untersuchten Modellansätze

Aus der schrittweisen Kombination der Entscheidungsbäume resultiert ein leistungsstarkes Ensemblemodell. Der Algorithmus ist nicht nur vergleichsweise genau, sondern zeichnet sich auch durch geringe Trainings- und Prognosezeiten aus.

baut und mit den verbleibenden 20 % der Daten hinsichtlich ihrer Prognosegenauigkeit getestet. Die Bestimmung der Hyperparameter zur Optimierung der Prognosemodelle erfolgte mit den Trainingsdaten im Rahmen einer Fünffach-Kreuzvalidierung. Die Güte der Modelle wurde hinsichtlich zweier Fragestellungen bewertet:

- Regressionsgüte: Wie gut kann das Modell die relative Ergiebigkeit als genauen numerischen Wert vorhersagen?
- Klassifizierungsgüte: Wie gut kann das

Modell vorhersagen, ob ein kritischer Ergiebigkeitswert (80 % des zuletzt beobachteten Höchstwertes) [7] unterschritten wird?

Die Regressionsgüte wurde anhand des Bestimmtheitsmaßes (r^2), der Wurzel der mittleren quadratischen Abweichung (engl. RMSE) und des mittleren absoluten Fehlers (engl. MAE) bestimmt. Für die Bestimmung der Klassifizierungsgüte wurde die Trefferquote (engl. „sensitivity“) und die Genauigkeit (engl. „precision“) herangezogen. Die Klassifizierung der relativen Ergiebigkeit in Werte $< 80\%$ und $\geq 80\%$ wurde a posteriori durchgeführt, das heißt das Modell wurde auf die relative Ergiebigkeit als numerischen Wert trainiert und die Ergiebigkeitsklassen wurden aus den Modellprognosen abgeleitet. Tabelle 1 zeigt die Modellgüte für die sieben Modellansätze und die ausgewählten Indikatoren.

Das baumbasierte Ensemble-Modell „Gradient Boosting“ kann die relative Ergiebigkeit der Brunnen des OOWV mit sehr hoher Genauigkeit wiedergeben. Das Modell kann über 80 % der Varianz in den Daten erklären ($r^2 = 0,81$). Der mittlere absolute Fehler liegt im Durchschnitt bei 5 % bezogen auf die relative Ergiebigkeit. Das Gradient-Boosting-Modell gibt 88 % der Beobachtungen mit einer relativen Ergiebigkeit $< 80\%$ richtig wieder (Trefferquote). 84 % der Modellprognosen mit einer relativen

Ergiebigkeit $< 80\%$ liegen tatsächlich in dieser Ergiebigkeitsklasse (Genauigkeit). Die Falsch-Positiv-Rate, das heißt der Anteil an Beobachtungen für den das Modell fälschlicherweise eine Ergiebigkeit $< 80\%$ prognostiziert, liegt bei 8 %. Abbildung 6 zeigt die Mess- und Prognoseergebnisse des Gradient-Boosting-Modells für einen Beispielbrunnen des OOWV.

Das Random-Forest-Modell hat sowohl für die Regression als auch für die Klassifikation eine ähnlich hohe Modellgüte wie das Gradient-Boosting-Modell. Das Neuronale Netz liefert in den untersuchten Varianten geringfügig schlechtere Ergebnisse. Den größten Modellfehler haben die regressionsanalytischen Ansätze (MARS, Multiple Lineare Regression, Logistische Regression und Cox Proportional Hazards). Aus Gründen der hohen Modellgüte und der vergleichsweise geringen Trainingszeiten wurde das Gradient-Boosting-Modell für die weiteren Zustandsprognosen ausgewählt.

Zustandsprognosen

Für das gesamte Versorgungsgebiet prognostiziert das Gradient-Boosting-Modell unter der hypothetischen Annahme, dass alle Brunnen ohne weitere Regenerierungen bis zum Jahr 2050 weiterbetrieben werden (Szenario „ungestörte Alterung“), einen durchschnittlichen Ergiebigkeitsverlust von 0,5 % pro Jahr (Abb. 7). Während die Ergiebigkeit aller Brunnen zum Zeitpunkt der jeweils letzten Messung noch bei durchschnittlich 81 % lag, läge sie für das Szenario der ungestörten Alterung im Prognosejahr 2050 noch bei 67 %. Bei 73 % der Brunnen wird die relative Ergiebigkeit den Prognosen zufolge dann um mehr als 20 % unter ihrem Maximalwert liegen.

Die Entwicklung der Brunnenergiebigkeit ist regional unterschiedlich. Während in einigen Wasserwerken die relative Ergiebigkeit schon jetzt bei einem Großteil der Brunnen unter einen kritischen Wert von 80 % gefallen ist, gibt es andere Wasserwerke, in denen bis 2050 den Prognosen zufolge noch alle Brunnen in einem guten Zustand sind.

Fazit

In Zusammenarbeit von FIT/FWT, KWB und dem OOWV wurde ein umfangreicher Datensatz zur Leistungsfähigkeit der Brunnen und ihren möglichen Ein-




Abb. 6 Ergiebigkeits-Messungen (schwarze Punkte) und Modellprognosen des Gradient-Boosting-Modells (grüne Linie) für einen Beispiel-Brunnen. Die blau-gestrichelten vertikalen Linien zeigen die Zeitpunkte durchgeführter Regenerierungen. Die rot-gestrichelte horizontale Linie zeigt den kritischen Wert von 80 % relativer Ergiebigkeit.




Abb. 7 Verteilung der prognostizierten relativen Ergiebigkeit über alle Brunnen bis 2050 für ein hypothetisches Szenario ohne Sanierungen (schwarze Linie: Mittelwert; hellblaues Band: gesamte Spannweite der Werte; blaue gestrichelte Linien: 5- bzw. 95 %-Perzentil)

flussfaktoren aufgebaut. Basierend auf diesen Daten wurden die Einflussfaktoren für die Brunnenalterung untersucht und Prognosemodelle für den Zustand der Förderbrunnen entwickelt. Mit einem ausgewählten Modellansatz wurden Vorhersagen zur Ergiebigkeit der Brunnen über die nächsten 30 Jahre gemacht.

Von den insgesamt über 30 untersuchten Einflussfaktoren haben neben dem Alter des Brunnens die Häufigkeit und der Zeitpunkt der durchgeführten Regenerierungen, die tägliche Brunnenlaufzeit und die Wasserqualität eine besondere Bedeutung für die Ergiebigkeit. Standorteigenschaften wie die Anzahl an Nachbarbrunnen und bauliche Eigenschaften spielen – mit Ausnahme der Filtertiefe – eine untergeordnete Rolle. Die Untersuchungen deuten auf zwei für die Förderbrunnen des OOWV wesentliche Alterungsprozesse hin: die Eisenverockerung und die Verkalkung. Um das Verockerungsrisiko gering zu halten, wird empfohlen, bei zukünftigen Brunnenerneuerungen nach Möglichkeit eine Filtertiefe von mindestens 40 m einzuhalten und die Anzahl an Brunnenschaltungen so gering wie möglich zu halten.

Mit dem baumbasierten Machine-Learning-Modell „Gradient Boosting“ lässt sich die relative Ergiebigkeit der Brunnen mit hoher Genauigkeit vorhersagen (mittlerer Fehler von ± 5 %). In neun von zehn Fällen wird ein kritischer Leistungsrückgang von über 20 % korrekt klassifiziert. Sensitivitätsuntersuchungen deuten darauf hin, dass sich die Modellgüte mit zunehmender Anzahl an Trainingsdaten noch verbessern ließe. Erste Zustandsprognosen zeigen, dass ohne weitere Regenerierungen und Erneuerungen mit einem mittleren Ergiebigkeitsverlust von 0,5 % pro Jahr zu rechnen ist, wobei es starke regionale Unterschiede im Versorgungsgebiet des OOWV gibt.

Mit dem entwickelten Brunnenalterungsmodell können Wasserwerke, Brunnenfassungen und einzelne Brunnen hinsichtlich ihres aktuellen und zukünftigen Sanierungsbedarfes priorisiert werden. Zukünftig soll das Modell für die bedarfsorientierte Planung von Regenerierungen und Erneuerungen von Förderbrunnen, die Identifizierung von Energieoptimierungspotenzialen und die langfristige Investitionssteuerung genutzt werden und so einen wichtigen Beitrag zur öffentlichen Daseinsvorsorge und dem Ressourcenschutz leisten. Die entwickelte Methodik lässt sich auch auf andere Versorgungsgebiete übertragen.

Literatur

- [1] David Steffebauer et al. (2022): D2.2: Performance and return on investment of urban water systems. www.digital-water.city.
- [2] Cramér, H. (1946): *Mathematical Methods of Statistics*. Princeton: Princeton University Press (Chapter 21. The two-dimensional case).
- [3] Breiman, L. (2001): Random Forests. *Machine Learning*, 45, 5-32.
- [4] Wei, P., Zhenzhou L., & Jingwen S. (2015): Variable importance analysis: a comprehensive review. *Reliability Engineering & System Safety* 142: 399-432.
- [5] Wiacek, H. (2005): *Brunnenmonitoring zur optimalen Brunnennutzung und -pflege*. Johannes Gutenberg-Universität in Mainz. Dissertation.
- [6] Chen, T., & Guestrin, C. (2016): XGBoost: A Scalable Tree Boosting System. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785–794). New York, NY, USA: ACM.
- [7] DVGW (2007): *Brunnenregenerierung – Arbeitsblatt W130*. Deutscher Verein des Gas- und Wasserfaches.

Autoren

Dr. Mathias Riechel
Cyril Roth
Fichtner Water & Transportation GmbH
Franklinstr. 26a
10587 Berlin
Tel.: +49 (0) 30 609765 02
mathias.riechel@fwt.fichtner.de
www.fwt.fichtner.de

Dr. Siri Hoppenau
Karen Hüske
Jürgen Sander
Dr. Ratko Posta
Oldenburgisch-Ostfriesischer Wasserverband

Hans-Hendrik Huber
Fichtner IT Consulting GmbH

Michael Rustler
Kompetenzzentrum Wasser Berlin gGmbH



Erfahren Sie mehr über die **-bbr!**
www.facebook.com/bbrfachmagazin