

# HENRY

Hydraulic Engineering Repository

Ein Service der Bundesanstalt für Wasserbau

---

Conference Paper, Published Version

**Zounemat-Kermani, Mohammad; Matta, Elena; Hinkelmann, Reinhard**

## **Anwendung von künstlichen neuronalen Netzen im Wasserbau**

Dresdner Wasserbauliche Mitteilungen

Zur Verfügung gestellt in Kooperation mit/Provided in Cooperation with:

**Technische Universität Dresden, Institut für Wasserbau und technische Hydromechanik**

---

Verfügbar unter/Available at: <https://hdl.handle.net/20.500.11970/107046>

Vorgeschlagene Zitierweise/Suggested citation:

Zounemat-Kermani, Mohammad; Matta, Elena; Hinkelmann, Reinhard (2020): Anwendung von künstlichen neuronalen Netzen im Wasserbau. In: Technische Universität Dresden, Institut für Wasserbau und technische Hydromechanik (Hg.): Interdisziplinärer Wasserbau im digitalen Wandel. Dresdner Wasserbauliche Mitteilungen 63. Dresden: Technische Universität Dresden, Institut für Wasserbau und technische Hydromechanik. S. 21-30.

### **Standardnutzungsbedingungen/Terms of Use:**

Die Dokumente in HENRY stehen unter der Creative Commons Lizenz CC BY 4.0, sofern keine abweichenden Nutzungsbedingungen getroffen wurden. Damit ist sowohl die kommerzielle Nutzung als auch das Teilen, die Weiterbearbeitung und Speicherung erlaubt. Das Verwenden und das Bearbeiten stehen unter der Bedingung der Namensnennung. Im Einzelfall kann eine restriktivere Lizenz gelten; dann gelten abweichend von den obigen Nutzungsbedingungen die in der dort genannten Lizenz gewährten Nutzungsrechte.

Documents in HENRY are made available under the Creative Commons License CC BY 4.0, if no other license is applicable. Under CC BY 4.0 commercial use and sharing, remixing, transforming, and building upon the material of the work is permitted. In some cases a different, more restrictive license may apply; if applicable the terms of the restrictive license will be binding.



# Anwendung von künstlichen neuronalen Netzen im Wasserbau

Mohammad Zounemat-Kermani  
Elena Matta  
Reinhard Hinkelmann

Künstliche neuronale Netze (KNN) haben sich bereits als leistungsfähige Methoden für eine Reihe von Fragestellungen im Wasserbau erwiesen. Nach einer kurzen Einführung zu Methoden und Werkzeugen wird die Anwendung von KNN für die Vorhersage von Wasserständen für die Binnenschifffahrt, von Abflüssen und Sedimenttransport, von langfristigen Depositions- und Erosionsvorgängen sowie von Geruch in abwassertechnischen Anlagen beschrieben. Aufgrund der stetig wachsenden Verfügbarkeit von Daten, Methoden und Werkzeugen sowie der relativ kurzen Rechenzeiten werden KNN zukünftig stark an Bedeutung im Wasserbau gewinnen. Nachteilig ist ihre eingeschränkte Übertragbarkeit.

Stichworte: Künstliche Neuronale Netze, Big Data, FFBP, LSTM, NARX

## 1 Einleitung

Künstliche neuronale Netze (KNN, ANN: Artificial Neural Networks) haben eine breite Anwendung im Wasser- und Umweltingenieurwesen gefunden, so auch im Wasserbau. Das gewachsene Interesse in den letzten Jahren resultiert zum einen aus der stetig wachsenden Verfügbarkeit von Daten ('Big Data') und zum anderen aus der Verfügbarkeit von Modellen und Methoden bzw. Toolboxen, von denen viele Open Source sind.

## 2 Methoden


Bei KNN handelt es sich um rein datengetriebene oder Black-Box Modelle, d.h. es werden ‚nur‘ Eingangs- und Ausgangsgrößen eines Systems benötigt. Umfangreiche und flächendetaillierte Informationen, beispielsweise zu

Höhen, Landnutzung, Böden, Anfangs- und Randbedingungen, wie hydrologische und hydro-numerische Modelle es in unterschiedlichen Auflösungen benötigen, sind nicht erforderlich. Weiterhin sind die Rechenzeiten i.d.R. relativ kurz, da – insbesondere im Vergleich zu hydro-numerischen Modellen – keine großen Systeme partieller Differentialgleichungen mit vielen Hunderttausenden oder Millionen Knoten gelöst werden müssen.

Bei KNN handelt es sich um verknüpfte Netzwerke, die i.d.R. aus drei Schichten (Input, Hidden und Output Layer) bestehen (Abb. 1). Die Layer sind verknüpft durch Neuronen, die Information erhalten, verarbeiten und weiterleiten. Bei klassischen KNN ist der Informationsfluss vom Input über den Hidden zum Output Layer (feed forward; z.B. Multi-Layer Perceptron Neural Network, MLP), während fortgeschrittenere Techniken wie rekurrente KNN auch den Rückfluss von Informationen berücksichtigen und so ein Erinnerungsvermögen abbilden (z.B. Long Short-Term Memory Neural Network, LSTM). Zur Weiterleitung der Informationen, zu deren Verarbeitung sowie zu beiden Gruppen (feed forward, rekurrent) gibt es eine Reihe von Methoden (Mosavi et al. 2018).

KNN werden in eine Trainings- bzw. Kalibrierungs- und eine Test- bzw. Validierungsphase untergliedert. Hierfür sind große Datensätze wünschenswert, es sollten mindestens etwa 500 Daten zur Verfügung stehen. Ca. 70 – 80 % der Daten wird für das Training verwendet, der Rest für das Testen. Im Anschluss sind sie dann für Vorhersagen einsetzbar.

KNN sind beispielsweise verfügbar in OpenNN ([www.opennn.net](http://www.opennn.net)), Keras (<https://keras.io>) in Verbindung mit TensorFlow ([www.tensorflow.org](http://www.tensorflow.org)), MATLAB oder R, wobei insbesondere die Open Source Tools Hochleistungsrechnen (Paralleles Rechnen; Graphical Processing Units, GPU) nutzen.



**Abbildung 1:** Struktur von feed forward und rekurrenten KNN


### 3 Anwendungen von KNN

#### 3.1 Vorhersage von Wasserständen für die Binnenschifffahrt

Im Rahmen des Forschungsprojektes ‚Digitaler Schifffahrtsassistent‘ wurde in Zusammenarbeit mit der Bundesanstalt für Gewässerkunde (BFG), Koblenz und dem Unternehmen BearingPoint, Berlin eine bedarfsorientierte Anwendung (App) zur Routen- und Ladungsplanung für die Binnenschifffahrt entwickelt (Schmidt et al. 2019). Ein wesentlicher Bestandteil dieser App waren Wasserstandsvorhersagen mit einem zeitlichen Horizont von bis zu 10 Tagen. Neben einem hydrologischen Modell der BFG wurde der Einsatz von KNN für verschiedene Pegel im Rheineinzugsgebiet untersucht (Abb. 2). Die Grundidee bestand aus der Vorhersage des Wasserstandes an einem Unterstrompegel anhand mehrerer gemessener Oberstrompegel, wobei bei den KNN die Methode Long Short-Term Memory (LSTM) des Open-Source Tools Keras eingesetzt wurde. Die Datenbasis bestand aus Tageswerten des Wasserstandes über mehrere Jahrzehnte. Beste Ergebnisse wurden durch eine Kombination der Methoden erzielt, indem die Ergebnisse des hydrologischen Modells als zusätzliche Eingangsgröße in das KNN eingebunden wurden, was zu den höchsten Bestimmtheitskoeffizienten am für Niedrigwasser kritischen Pegel Oestrich führte (Abb. 3, Ma et al. 2019).



**Abbildung 2:** Einzugsgebiet des Rheins bis zum Pegel Emmerich  
(Quelle: Bundesanstalt für Gewässerkunde (BFG), Koblenz)



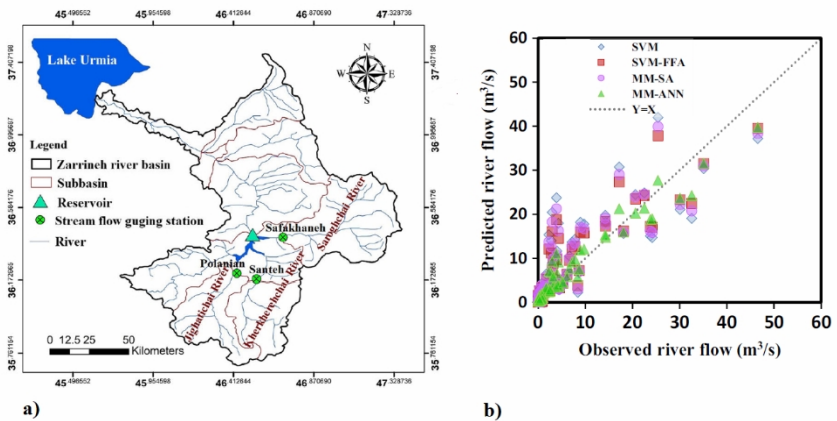
**Abbildung 3:** Bestimmtheitskoeffizient  $R^2$  für verschiedene Modelle (Zielpegel: Oestrich); aus *Ma et al. (2019)*

### 3.2 Vorhersage von Abflüssen und Sedimenttransport


Die Abflussvorhersage spielt eine wichtige Rolle in vielen Fragestellungen von Wasserbau und Wasserwirtschaft. Von besonderer Bedeutung ist hier u.a. die Vorhersage der Abflusspeaks sowie ihrer Zeitpunkte. Für solche Fragestellungen werden KNN in den letzten Jahren vermehrt eingesetzt (z.B. Sharma et al. 2015). In einer Studie von Ghorbani et al. (2019) wurden verschiedene Methoden der Künstlichen Intelligenz (KI) einschließlich KNN bzw. Multi-layer Perceptron (MLP) unter Verwendung von MATLAB für die Abflussvorhersage des Flusses Zarrineh im Iran eingesetzt, wobei die hohe Leistungsfähigkeit aller Methoden bestätigt wurde (Abb. 4).

Die Vorhersage von Sedimenttransport ist ebenfalls von großer Bedeutung im Wasserbau und in der Wasserwirtschaft. Sedimente werden im Einzugsgebiet oder im Flusslauf durch Erosionsvorgänge mobilisiert und lagern sich in Stauräumen ab, was zu einer Verminderung des Stauvolumens und entsprechender Gegenmaßnahmen (z.B. Ausbaggerungen) führt. Es ist daher wünschenswert, möglichst genaue Vorhersagewerkzeuge zu entwickeln und KNN werden seit einigen Jahren ebenfalls für solche Problemstellungen eingesetzt. Zounemat-Kermani (2016) haben verschiedene Metho-

den, u.a. auch KNN bzw. MLP unter Verwendung von MATLAB, für die Vorhersage von Schwebstoffkonzentrationen im Fluss San Joaquin, Kalifornien basierend auf gemessenen Zeitreihen verglichen. Die Ergebnisse der Studie zeigen, dass alle Methoden sehr gut geeignet sind für eintägige Vorhersagen (Korrelationskoeffizient > 0.9, Nash-Sutcliffe Koeffizient > 0.85). In Abbildung 5 sind die Residuen der Schwebstoffkonzentrationen (Differenzen aus Berechnung und Messung) sowie ein Vergleich berechneter und gemessener Schwebstoffkonzentrationen im Streudiagramm bzw. Scatterplot dargestellt.



**Abbildung 4:** a) Modellgebiet im Nordwesten Irans mit Pegelstationen, b) mit KNN bzw. MLP berechnete und gemessene Abflüsse in der Testphase (SVM: Support Vector Machine; SVM-FFA: SVM kombiniert mit Firefly Algorithm; MM-SA: Multiple Models – Simple Averaging; MM-ANN: Multiple Models KNN)



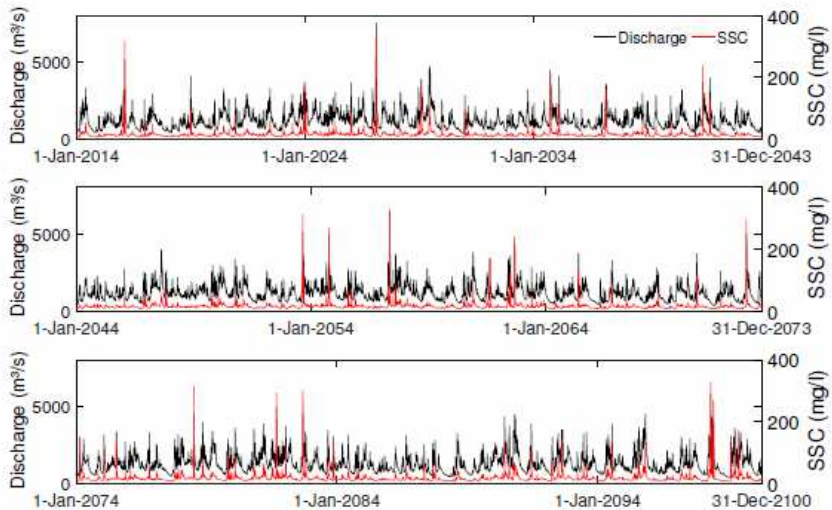
**Abbildung 5:** Mit KNN bzw. MLP berechnete und gemessene Schwebstoffkonzentrationen in der Testphase: a) Residuen, b) Scatterplot

### 3.3 Vorhersage von langfristigen Depositions- und Erosionsvorgängen

Im Rahmen eines Forschungsprojektes (Zhang, Hinkelmann 2017) und der Dissertation von Zhang (2018) wurden konzeptionelle Vereinfachungen für langfristige Sedimentationsprozesse bis 2100 entwickelt, wobei der Schwerpunkt auf der Ermittlung von Depositions- und Erosionsmengen im Bereich der Staustufe Iffezheim lag. Hierzu wurden auch KNN eingesetzt, wobei die Methoden Feed Forward Back Propagation (FFBP) und sog. Wavelet ANN (WANN) unter Verwendung von MATLAB verwendet wurden. Die täglichen Vorhersagen der Sedimentkonzentrationen basierten auf Werten der Abflüsse des aktuellen Tages sowie Werten der Abflüsse und Sedimentkonzentrationen mehrerer Vortage, wobei für die Phasen Kalibrierung bzw. Training und Validierung bzw. Testen ein Datensatz von täglichen Werten von Sedimentkonzentrationen und Abflüssen über 36 Jahren von der BFG zur Verfügung gestellt wurde. Ein Vergleich der beiden KNN untereinander und mit einer klassischen Sedimentkonzentrations-Abfluss-Beziehung (SRC) anhand von drei Fehlerkriterien zeigte, dass KNN bzw. FFBP in den meisten Fällen (deutlich) besser als WANN und SRC ist (Abb. 6). Darauf aufbauend wurden mit dem KNN Vorhersagen der Sedimentkonzentrationen bis 2100 durchgeführt, wobei Abflussvorhersagen bzw. -projektionen aus dem KLIWAS Programm (KLIWAS 2015) seitens der BFG bereitgestellt wurden (Abb. 7).

Model	Optimized structure	Calibration			Validation		
		RMSE (mg/l)	MBE (mg/l)	DC	RMSE (mg/l)	MBE (mg/l)	DC
ANN	5,8,1	11.515	-0.678	0.71	10.517	-1.305	0.52
WANN	5,2,1	16.950	-3.231	0.33	10.723	-0.313	0.49
SRC	-	17.011	0.0258	0.34	10.983	-3.021	0.46

**Abbildung 6:** Vergleich unterschiedlicher Methoden (ANN: Artificial Neural Network, hier KNN; WANN: Wavelet ANN; SRC: Sediment-Rating Curve, Error, Wurzel der mittleren quadratischen Fehlersumme; MBE: Mean Bias Sedimentkonzentrations-Abfluss-Beziehung) anhand unterschiedlicher Fehlerkriterien (RMSE: Root Mean Square Error, mittlerer Fehler; DC: Determination Coefficient, Bestimmtheitskoeffizient); aus Zhang (2018)



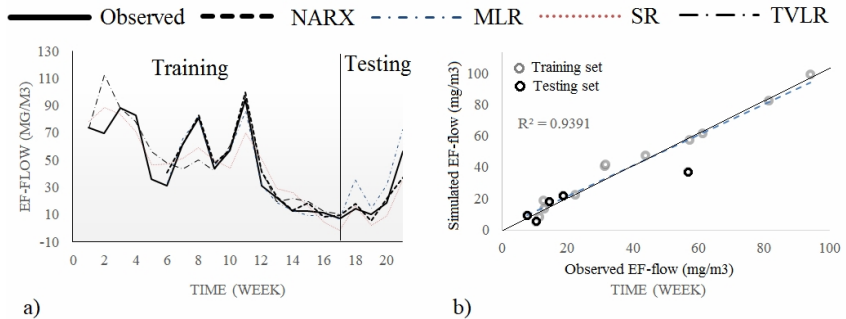
**Abbildung 7:** Vorhersage der Sedimentkonzentrationen bis 2100 mit KNN basierend auf Abflussprojektionen von *KLWAS* (2015); aus Zhang (2018)

### 3.4 Vorhersage von Geruch in abwassertechnischen Anlagen

Kläranlagen und Kanalnetzsysteme erzeugen und emittieren beträchtliche Mengen an geruchsbeeinträchtigenden Gasen wie z.B. Schwefelwasserstoff ( $H_2S$ ) oder Lachgas ( $N_2O$ ). Um entsprechende Gegenmaßnahmen möglichst gezielt einsetzen zu können, sind Vorhersagewerkzeuge von großer Bedeutung. Auf der einen Seite gibt es verschiedene prozessorientierte empirische und numerische Modelle. Auf der anderen Seite wurden in der Vergangenheit bereits viele Datensätze zu dieser Problematik erhoben und sind seit einiger Zeit in entsprechenden Datenbanken verfügbar, was den Einsatz von KNN nahelegt. Auch wenn es erste Arbeiten hierzu gibt, so befindet sich diese Thematik noch in einer frühen Phase. In diesem Kontext haben Zounemat-Kermani et al. (2019) einen Überblick über den Einsatz von KNN für die Vorhersage von Geruch bzw. Schwefelwasserstoffemissionen in abwassertechnischen Anlagen gegeben und Berechnungen mit fünf Eingangsgrößen (gelöste Schwefelkomponenten, biochemischer Sauerstoffbedarf, Temperatur, Abfluss und pH-Wert) durchgeführt. Als Methode wurde Multivariate Nonlinear Autoregressive Exogenous Neural Network (NARX) in MATLAB entwickelt und für die Vorhersage der wöchentlichen Schwefelwasserstoffkonzentrationen in einer Kläranlage angewandt. In



Abbildung 8 ist ein Vergleich von NARX mit Regressionsmethoden (Multiple Linear Regression, MLR; Stepwise Regression, SR; Two-Variate Logarithmic Regression, TVLR) und Messwerten dargestellt. Es ist deutlich zu sehen, dass NARX dichter an den Messwerten liegt als die Regressionsmethoden.



**Abbildung 8:** a) Vergleich von mit unterschiedlichen Methoden berechneten und gemessenen Schwefelwasserstoffkonzentrationen (EF-FLOW: Emission Factor Flow, Schwefelwasserstoffkonzentration) b) Scatterplot von NARX; verändert nach *Zounemat-Kermani et al. (2019)*

## 4 Schlussfolgerungen

Im Rahmen dieses Beitrages konnte aufgezeigt werden, dass KNN bereits in mehreren Bereichen des Wasserbaus erfolgreich eingesetzt und vielversprechende Ergebnisse erzielt wurden. KNN können grundsätzlich in Betracht gezogen werden, wenn zu einer Fragestellung umfangreiche Daten zur Verfügung stehen. Es existieren verschiedene Methoden und leistungsfähige Werkzeuge (auch Open Source). KNN können ohne Alternativmethode sein, können besser sein als klassische Methoden oder können in Kombination mit klassischen Methoden zu verbesserten Vorhersagen führen. Zum Arbeiten mit KNN sind eigentlich keine speziellen Kenntnisse erforderlich; bei der Auswahl der Modelltechnik, der zahlreichen Parameteroptionen innerhalb der Techniken und der zu berücksichtigenden Eingangsgrößen sind gute Grundkenntnisse in der zu bearbeitenden Fragestellung vorteilhaft. Vorteilhaft ist weiter, dass KNN nur relativ kurze Rechenzeiten erfordern, insbesondere wenn sie mit mehrdimensionalen hydro-numerischen Modellen verglichen werden. Im Zuge der stetig wachsenden Verfügbarkeit von Daten (Big

Data), Methoden und Werkzeugen ist davon auszugehen, dass KNN stark an Bedeutung gewinnen und sich weitere Potentiale im Wasserbau und vielen weiteren Disziplinen erschließen werden.

Nachteilig bei KNN ist, dass ihre Übertragbarkeit sehr eingeschränkt ist. Für ein ähnliches Problem kann eventuell die Netzwerkarchitektur übernommen werden, die Parametereinstellungen müssen sicherlich angepasst werden. Ggf. sind aber doch andere Architekturen besser und / oder weitere Eingangsgrößen in Betracht zu ziehen. Etwas überspitzt formuliert kann man sagen, dass man für ein neues Problem ,quasi wieder bei null beginnt.

## 5 Literatur

- Ghorbani, M. A., Khatibi, R., Karimi, V., Yaseen, Z. M., & Zounemat-Kermani, M. (2018): Learning from multiple models using artificial intelligence to improve model prediction accuracies: application to river flows. *Water resources management*, 32(13), 4201-4215
- KLIWAS (2015): Auswirkungen des Klimawandels auf Wasserstraßen und Schifffahrt – Entwicklung von Anpassungsoptionen. Abschlussbericht, Bundesministerium für Verkehr und Digitale Infrastruktur, Bonn
- Ma, Y., Matta, E., Meißner, D., Schellenberg, H. & Hinkelmann, R. (2019): Can machine learning improve the accuracy of water level forecasts for inland navigation? Case study: Rhine River Basin, Germany. 38th IAHR World Congress Panama City 2019, Water - Connecting the world
- Mosavi, A., Ozturk, P., & Chau, K. W. (2018): Flood prediction using machine learning models: Literature review. *Water*, 10(11), 1536
- Schmidt, A., Schellenberg, H., Tretter, G., Hinkelmann, R., Matta, E., Scheer, C., Meißner, D. und Richter, J. (2019): Entwicklung eines digitalen Schifffahrtsassistenten. Forschungsbericht, Förderkennzeichen: 19F2051A bis D, mFUND, Bundesministerium für Verkehr und Digitale Infrastruktur, Bonn
- Sharma, N., Zakallah, M., Tiwari, H., & Kumar, D. (2015): Runoff and sediment yield modeling using ANN and support vector machines: a case study from Nepal watershed. *Modeling Earth Systems and Environment*, 1(3), 23
- Zhang, Q. (2018): Conceptual simplifications for long-term sediment transport simulations: application to Iffezheim reservoir, Germany. Dissertation, Nr. 25, Schriftenreihe des Instituts für Bauingenieurwesen, Technische Universität Berlin
- Zhang, Q. & Hinkelmann, R. (2017): Abschätzung der Langzeitvolumen-änderung an der Staustufe Iffezheim. Abschlussbericht zum BFG-Projekt Sedimentmanagement Oberrhein

Zounemat-Kermani, M. (2016): Assessment of several nonlinear methods in forecasting suspended sediment concentration in streams. *Hydrology Research*, 48(5), 1240-1252

Zounemat-Kermani, M., Stephan, D., & Hinkelmann, R. (2019): Multivariate NARX neural network in prediction gaseous emissions within the influent chamber of wastewater treatment plants. *Atmospheric Pollution Research*, 10(6), 1812-1822

### **Danksagung**

Die Autoren bedanken sich bei der Alexander von Humboldt-Stiftung für die Bereitstellung eines Georg Forster-Forschungsstipendiums für erfahrene Wissenschaftler an Prof. Mohammad Zounemat-Kermani am Fachgebiet Wasserwirtschaft und Hydrosystemmodellierung, TU Berlin.

Autoren:

Prof. Mohammad Zounemat-Kermani    Dr. Elena Matta

Department of Water Engineering  
Shahid Bahonar University of Kerman  
Bahman Blvd. 22  
76169-14111 Kerman  
Iran

Tel.:            +98 34 3132 2668  
Fax:            +98 34 3132 2600  
E-Mail:        zounemat@uk.ac.ir

Department    Water        Engineering  
Campus El Gouna  
Technische Universität Berlin  
Ackerstr. 76  
13355 Berlin

Tel.:            +49 30 314 75711  
Fax:            +49 30 314 75716  
E-Mail:        elena.matta@tu-berlin.de

Prof. Reinhard Hinkelmann

Fachgebiet Wasserwirtschaft und  
Hydrosystemmodellierung  
Technische Universität Berlin  
Gustav-Meyer Allee 25  
13355 Berlin

Tel.:            +49 30 314 72428  
Fax:            +49 30 314 72430  
E-Mail:        reinhard.hinkelmann@  
                  wahyd.tu-berlin.de