



FACHHOCHSCHULE KIEL
University of Applied Sciences

EKSH

Gesellschaft für
Energie und Klimaschutz
Schleswig-Holstein



Kiel Netz GmbH



Gemeindewerke Heikendorf

Abschlussbericht – Projekt Nr. 8/12-54

KI-basiertes Forecasting und Microforecasting von Energieerzeugung und -verbrauch

Prof. Dr. Jan-Hendrik Meier

jan-hendrik.meier@fh-kiel.de

Prof. Dr. Stephan Schneider

stephan.schneider@fh-kiel.de

Prof. Dr. Andreas Luczak

andreas.luczak@fh-kiel.de

Fatna Barkouch, Wiss. Mitarbeiterin

fatna.barkouch@fh-kiel.de

Tim-Henning Sator, Wiss. Mitarbeiter

tim-henning.sator@fh-kiel.de

Jan-Hendrik Meier

Stephan Schneider

Inhaltsverzeichnis

Abbildungsverzeichnis	3
1 Einleitung	4
2 Projekt	7
3 Literaturüberblick	8
3.1 <i>Betrachtungsebene Stromverbrauch</i>	0
3.1.1 Orts- und Stadtnetze und Quartiere	2
3.1.2 Haushalte	2
3.1.3 Gebäude(komplex)	2
3.1.4 Gerät	3
3.2 <i>Betrachtungsebene Stromerzeugung</i>	3
3.2.1 Windenergie	4
3.2.2 Solarenergie / Photovoltaik	4
3.2.3 Kombinierte Energieerzeuger	5
3.2.4 Wellenenergie	5
3.3 <i>Betrachtungsebene Erzeugung und Verbrauch</i>	5
4 Daten	7
4.1 <i>Inputgrößen (X)</i>	7
4.1.1 Kontextuelle Merkmale	7
4.1.2 Autokorrelierte Merkmale	8
4.2 <i>Outputgröße(n) (Y)</i>	9
4.3 <i>Preprocessing</i>	10
4.3.1 Fehlende Werte	10
4.3.2 Ausreißer	10
4.3.3 Zeitreihen	11
4.3.4 Differenziation / Stationarität	12
4.3.5 Resampling der Datenmenge eingedenk der Lags der Merkmale (X und Y)	13
4.3.6 Partitionierung	13
4.3.7 Skalierung / Normalisierung	14
5 Überblick und theoretische Grundlagen zu künstlicher Intelligenz	14
5.1 <i>Ursprung und Definition von künstlicher Intelligenz</i>	14
5.2 <i>KI-Typen</i>	16

5.3	<i>Vier Grundtypen</i>	17
5.3.1	Typ 1: Reaktive Maschinen (Reactive machines)	17
5.3.2	Typ 2: Begrenzter Speicher (Limited memory)	17
5.3.3	Typ 3: Theorie des Geistes (Theory of mind)	17
5.3.4	Typ 4: Selbstwahrnehmung (Self-awareness)	17
5.4	<i>Supervised vs. unsupervised Learning</i>	17
5.5	<i>Machine Learning und Deep Learning</i>	18
5.5.1	Kurze Einführung und mathematische Grundlegung	18
5.5.2	Convolutional Neural Network (CNN)	24
5.5.3	Long Short-Term Memory (LSTM)	26
5.6	<i>Autoregressive Modelle</i>	29
5.6.1	AR-Modell	30
5.6.2	MA-Modell	32
5.7	<i>Vektorautoregressive Modelle VAR</i>	32
6	Modellauswahl und Ergebnisse	33
6.1	<i>Modelle</i>	34
6.1.1	Long Short-Term Memory Modell (LSTM)	34
6.1.2	Bidirectional LSTM Modell (BiLSTM)	36
6.1.3	Convolutional Neuronales Network (CNN):	37
	<i>CNN-BiLSTM-Modell</i>	37
	<i>Convolutional LSTM (ConvLSTM) Modell:</i>	38
6.1.4	VGG-Architektur, Inception Insep-Architektur, Inception Insp-LSTM-Architektur und Xception-Architektur	38
6.1.5	Inception-Insep-Architektur	39
6.1.6	Inception Insp-LSTM-Architektur	39
6.1.7	VGG-LSTM-Architektur	39
6.1.8	Xception-Architektur	39
6.2	<i>Ergebnisse der Prognosemodelle</i>	41
7	Fazit	46
8	Quellen	47

Abbildungsverzeichnis

Abbildung 1: Gantt-Diagramm für die Projektplanung.....	7
Abbildung 2: Übersicht der unterschiedlichen Prognosemethoden	0
Abbildung 3: Verwendete Methodiken innerhalb der Verbrauchsebene	1
Abbildung 4: Datenerzeuger für Prognosemodelle der Verbrauchsebene	1
Abbildung 5: Verwendete Methodiken innerhalb der Erzeugungsebene	4
Abbildung 6: Verwendete Methodiken innerhalb der Ebene Erzeugung und Verbrauch	6
Abbildung 7: Klassifikationstypen an KI.....	16
Abbildung 8: Schematische Darstellung eines künstlichen neuronalen Netzes	19
Abbildung 9: LSTM-Architektur	35
Abbildung 10: BiLSTM Architektur.....	36
Abbildung 11: CNN-Architektur.....	37
Abbildung 12 VGG-Architektur.....	38
Abbildung 13 VGG-LSTM-Architektur.....	39
Abbildung 14: Vergleich zwischen tatsächlicher und vorhergesagter Belastung für die Testdaten der durch D1 dargestellten Flächenaktivität.....	42
Abbildung 15: Vergleich zwischen tatsächlicher und vorhergesagter Belastung aus den Testdaten der durch D2 dargestellten Flächenaktivität.....	42
Abbildung 16: Vergleich zwischen tatsächlicher und vorhergesagter Belastung aus den Testdaten der durch D3 dargestellten Flächenaktivität.....	43
Abbildung 17: Vergleich zwischen tatsächlicher und vorhergesagter Belastung aus den Testdaten der durch D4 dargestellten Flächenaktivität.....	44
Abbildung 18: Vergleich zwischen tatsächlicher und vorhergesagter Belastung aus den Testdaten der durch D6 dargestellten Flächenaktivität.....	44

1 Einleitung

Energie ist eine der wichtigsten Ressourcen unserer Zeit, wie die jüngsten multinationalen Ausnahmesituationen zeigen, die durch die COVID-19-Pandemie und den Überfall Russlands auf die Ukraine verursacht wurden und die zu einer tiefen Krise im Energiesektor geführt haben. Die derzeit vorherrschenden Umstände erweisen sich als historischen Wendepunkt hin zu sauberen und sicheren Energiesystemen und der zunehmenden Abkehr von fossilen Brennstoffen.¹ Prognosen zufolge wird der Ausbau der erneuerbaren Energien ein enormes Wachstum erfahren. Innerhalb der nächsten fünf Jahre werden erneuerbare Lösungen 90 % des weltweiten Stromausbaus abdecken und schließlich den größten Anteil am globalen Strommix tragen.²

Der Wachstumstrend der erneuerbaren Energien und die Diversifizierung des Strommixes gehen Hand in Hand mit erheblichen Herausforderungen, die sich aus der Volatilität und Unbeständigkeit der Stromerzeugung aus erneuerbaren Energiequellen ergeben. Um eine stabile, effiziente und effektive Stromversorgung zu gewährleisten, ist ein flexibles Management unter Verwendung akkurater Prognosen der Energielast von äußerster Relevanz.³ Die Modellierung von qualitativ hochwertigen Prognosen ist aufgrund der zahlreichen Faktoren, die die Stromerzeugung beeinflussen, sehr komplex, insbesondere im Bereich der erneuerbaren Energien. Bei den erneuerbaren Energiequellen hängt die Energieerzeugung von Faktoren ab, die schwer abzuschätzen sind, da der Input für die Erzeugung aufgrund klimatischer Bedingungen wie Windgeschwindigkeit und Sonneneinstrahlung schwankt und nicht immer saisonalen Mustern folgt.⁴ Auch die Höhe der Energienachfrage ist sehr komplex und schwer vorherzusagen, da sie von einer Vielzahl an Faktoren wie Kalenderinformationen, Wetterbedingungen und sozioökonomischen Faktoren abhängt.⁵ Daher sind Prognosemodelle idealerweise so konzipiert, dass sie alle relevanten Faktoren berücksichtigen und ihre individuellen Auswirkungen auf Energieangebot und -nachfrage einbeziehen. Die herkömmlichen Vorhersagemodelle im Bereich der Lastvorhersage bzw. *load forecasting* (LF) basieren entweder auf

¹ Vgl. International Energy Agency. „World Energy Outlook 2022“. Paris, 2022a. <https://www.iea.org/reports/world-energy-outlook-2022>.

² Vgl. International Energy Agency. „Renewables 2022“. Paris, 2022b. <https://www.iea.org/reports/renewables-2022>.

³ Vgl. Gal Dalal, Elad Gilboa, und Shie Mannor, „Hierarchical decision making in electricity grid management“, in *International conference on machine learning* (PMLR, 2016), 2197–2206; Cherrille Eid u. a., „Managing Electric Flexibility from Distributed Energy Resources: A Review of Incentives for Market Design“, *Renewable and Sustainable Energy Reviews* 64 (Oktober 2016): 237–47, <https://doi.org/10.1016/j.rser.2016.06.008>; Zhixi Shen u. a., „Model-independent approach for short-term electric load forecasting with guaranteed error convergence“, *IET Control Theory & Applications* 10, Nr. 12 (2016): 1365–73; Benjamin F Hobbs u. a., „Analysis of the value for unit commitment of improved load forecasts“, *IEEE Transactions on Power Systems* 14, Nr. 4 (1999): 1342–48; Ying Chen u. a., „Short-term load forecasting: Similar day-based wavelet neural networks“, *IEEE Transactions on Power Systems* 25, Nr. 1 (2009): 322–30; Gwo-Ching Liao und Ta-Peng Tsao, „Application of Fuzzy Neural Networks and Artificial Intelligence for Load Forecasting“, *Electric Power Systems Research* 70, Nr. 3 (August 2004): 237–44, <https://doi.org/10.1016/j.epsr.2003.12.012>.

⁴ Vgl. Ioannis Antonopoulos u. a., „Artificial Intelligence and Machine Learning Approaches to Energy Demand-Side Response: A Systematic Review“, *Renewable and Sustainable Energy Reviews* 130 (September 2020): 109899, <https://doi.org/10.1016/j.rser.2020.109899>.

⁵ Vgl. Wei Sun und Yi Liang, „Research of Least Squares Support Vector Regression Based on Differential Evolution Algorithm in Short-Term Load Forecasting Model“, *J. Renewable Sustainable Energy*, 2014; Carlo Cecati u. a., „A Novel RBF Training Algorithm for Short-Term Electric Load Forecasting and Comparative Studies“, *IEEE Transactions on Industrial Electronics* 62, Nr. 10 (Oktober 2015): 6519–29, <https://doi.org/10.1109/TIE.2015.2424399>.

statistischen Methoden wie Zeitreihenanalysemodellen, linearen Regressionen, allgemeinen exponentiellen Techniken⁶, auf maschinellem Lernen⁷ oder (hybriden) Deep Learning (DL)-basierten Modellen, wie insbesondere Long Short-Term Memory (LSTM)⁸, Convolutional Neural Network (CNN)⁹ oder Recurrent Neural Network¹⁰ für den kurzfristigen LF-Bereich bzw. *short-term* LF (STLF). DL-Methoden bieten jedoch eine erhebliche Möglichkeit zur Verbesserung der Prognosegenauigkeit im Rahmen des LF. Im Gegensatz zu traditionellen Prognosemodellen sind sie in der Lage, lineare und nichtlineare Korrelationen zu erkennen und können jede universelle Funktion annähern, einschließlich der Interaktionseffekte der Eingangsvariablen¹¹, während statistische Methoden scheitern, weil die Prognosequalität bei abrupten Änderungen der betrachteten Variablen abnimmt¹². Inzwischen hat die aktuelle Forschung in diesem Bereich umfangreiche Literatur hervorgebracht, insbesondere eine Vielzahl von Veröffentlichungen mit dem Schwerpunkt auf der Verbesserung der Trainingsfähigkeit neuronaler Netze, um die LF-Vorhersagegenauigkeit sowie die Effizienz zu optimieren und so die Ergebnisse der traditionellen Methoden zu übertreffen.¹³ Aus den genannten Gründen sind neuronale

⁶ Vgl. Fahad Javed u. a., „Forecasting for Demand Response in Smart Grids: An Analysis on Use of Anthropologic and Structural Data and Short Term Multiple Loads Forecasting“, *Applied Energy* 96 (August 2012): 150–60, <https://doi.org/10.1016/j.apenergy.2012.02.027>; W. Charytoniuk, M.S. Chen, und P. Van Olinda, „Nonparametric Regression Based Short-Term Load Forecasting“, *IEEE Transactions on Power Systems* 13, Nr. 3 (August 1998): 725–30, <https://doi.org/10.1109/59.708572>; Mengmeng Cai, Manisa Pipattanasomporn, und Saifur Rahman, „Day-Ahead Building-Level Load Forecasts Using Deep Learning vs. Traditional Time-Series Techniques“, *Applied Energy* 236 (Februar 2019): 1078–88, <https://doi.org/10.1016/j.apenergy.2018.12.042>; Ahmed Yousuf Saber und A K M Rezaul Alam, „Short Term Load Forecasting Using Multiple Linear Regression for Big Data“, in *2017 IEEE Symposium Series on Computational Intelligence (SSCI)* (2017 IEEE Symposium Series on Computational Intelligence (SSCI), Honolulu, HI: IEEE, 2017), 1–6, <https://doi.org/10.1109/SSCI.2017.8285261>; Xianghe Zhu und Min Shen, „Based on the ARIMA Model with Grey Theory for Short Term Load Forecasting Model“, o. J.; W. Christiaanse, „Short-Term Load Forecasting Using General Exponential Smoothing“, *IEEE Transactions on Power Apparatus and Systems* PAS-90, Nr. 2 (März 1971): 900–911, <https://doi.org/10.1109/TPAS.1971.293123>; Yacine Chakhchoukh, Patrick Panciatici, und Lamine Mili, „Electric Load Forecasting Based on Statistical Robust Methods“, *IEEE TRANSACTIONS ON POWER SYSTEMS* 26, Nr. 3 (2011); N. Amral, C. S. Ozveren, und D. King, „Short Term Load Forecasting Using Multiple Linear Regression“, in *2007 42nd International Universities Power Engineering Conference* (2007 42nd International Universities Power Engineering Conference, Brighton, UK: IEEE, 2007), 1192–98, <https://doi.org/10.1109/UPEC.2007.4469121>.

⁷ Vgl. Noman Shabbir u. a., „Comparison of Machine Learning Based Methods for Residential Load Forecasting“, in *2019 Electric Power Quality and Supply Reliability Conference (PQ) & 2019 Symposium on Electrical Engineering and Mechatronics (SEEM)* (2019 Electric Power Quality and Supply Reliability Conference (PQ) & 2019 Symposium on Electrical Engineering and Mechatronics (SEEM), Kärđla, Estonia: IEEE, 2019), 1–4, <https://doi.org/10.1109/PQ.2019.8818267>.

⁸ Vgl. Daniel L. Marino, Kasun Amarasinghe, und Milos Manic, „Building Energy Load Forecasting Using Deep Neural Networks“, in *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society* (IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society, Florence, Italy: IEEE, 2016), 7046–51, <https://doi.org/10.1109/IECON.2016.7793413>.

⁹ Vgl. Xishuang Dong, Lijun Qian, und Lei Huang, „Short-Term Load Forecasting in Smart Grid: A Combined CNN and K-Means Clustering Approach“, in *2017 IEEE International Conference on Big Data and Smart Computing (BigComp)* (2017 IEEE International Conference on Big Data and Smart Computing (BigComp), Jeju Island, South Korea: IEEE, 2017), 119–25, <https://doi.org/10.1109/BIGCOMP.2017.7881726>.

¹⁰ Vgl. Heng Shi, Minghao Xu, und Ran Li, „Deep Learning for Household Load Forecasting—A Novel Pooling Deep RNN“, *IEEE Transactions on Smart Grid* 9, Nr. 5 (September 2018): 5271–80, <https://doi.org/10.1109/TSG.2017.2686012>; Ljubisa Sehovac und Katarina Grolinger, „Deep Learning for Load Forecasting: Sequence to Sequence Recurrent Neural Networks With Attention“, *IEEE Access* 8 (2020): 36411–26, <https://doi.org/10.1109/ACCESS.2020.2975738>.

¹¹ Vgl. Guoqiang Zhang, B. Eddy Patuwo, und Michael Y. Hu, „Forecasting with Artificial Neural Networks“, *International Journal of Forecasting* 14, Nr. 1 (März 1998): 35–62, [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7).

¹² Vgl. D.C. Park u. a., „Electric Load Forecasting Using an Artificial Neural Network“, *IEEE Transactions on Power Systems* 6, Nr. 2 (Mai 1991): 442–49, <https://doi.org/10.1109/59.76685>.

¹³ Vgl. Muhammad Qamar Raza und Abbas Khosravi, „A Review on Artificial Intelligence Based Load Demand Forecasting Techniques for Smart Grid and Buildings“, *Renewable and Sustainable Energy Reviews* 50 (Oktober 2015): 1352–72, <https://doi.org/10.1016/j.rser.2015.04.065>.

Netze hochgradig qualifiziert und prädestiniert für die Lösung der Problemstellung der Prognose von Energieerzeugung- und verbrauch bzw. des LF und stellen in der Forschung die dominante Lösung für die Vorhersage im Bereich der Stromversorgung dar.¹⁴

Um den Herausforderungen der bevorstehenden Energiewende gerecht zu werden, den Anteil ökologischen Stroms im gesamten Strommix signifikant auszubauen und damit auf die Nutzung fossiler Energieträger sukzessive zu verzichten, ist eine möglichst akkurate Steuerung von Stromproduktion und -verbrauchsmengen von hoher Relevanz, mit dem sich das Drittmittelprojekt „KI-basiertes Forecasting und Microforecasting von Energieerzeugung und -verbrauch“ der Fachhochschule Kiel befasst. Die Modellierung zukünftiger Netzlasten erweist sich in Anbetracht einer Vielzahl von determinierenden Größen als ein äußerst komplexes, jedoch zugleich bedeutendes Forschungs- und Anwendungsgebiet für Wissenschaft und Praxis. Basierend auf einer möglichst exakten Prognose sollen Stromnetze geeigneter ausgelegt und geschaltet, Kraftwerkskapazitäten effizienter geplant und Stromspeichertechnologien sinnvoller eingesetzt werden. Das derzeitige Netzmanagement sowie die verwendeten Prognosemodelle stoßen angesichts eines sich schnell ändernden Energiemarktes oftmals an ihre Grenzen. Künstliche neuronale Netze (KNN) bieten ein hohes Potenzial, die Prognosegüte im Forecasting zu verbessern. Das Forschungsprojekt zielt darauf ab, leistungsstärkere KNN Typen, wie LSTM, CNN und hybride Lösungen aus KNN und klassischen Prognoseverfahren zu konzipieren und anzuwenden. Hierfür werden am Beispiel eines regionalen Niederspannungsnetzes Modelle entwickelt, welche an die speziellen örtlichen Gegebenheiten anpassbar sind.

¹⁴ Vgl. Jan-Hendrik Meier u. a., „KI-basiertes Forecasting und Microforecasting von Energieerzeugung und -verbrauch in dezentralen Strukturen“, in *Forschungsberichte zum Energiesystem X.0: Nr. 1: Intelligente und effiziente Vernetzung von Energieerzeugern und -verbrauchern auf Quartiersebene*, hg. von Gesellschaft für Energie und Klimaschutz Schleswig-Holstein GmbH, Studienreihe und Ergebnisbericht NEW 4.0, 2021, 154–74.

3 Literaturüberblick

Es konnten 227 Fachartikel zu Vorhersagemethoden für Stromverbrauch und Stromerzeugung identifiziert werden. Darunter fokussieren sich 104 Artikel auf Strombewegungen im Macrogrid, die anderen 123 Artikel behandeln Prognose-Modelle im Microgrid. Die Veröffentlichungen sind in den folgenden Tabellen aufgeführt:

Strommengenprognose in Macrogrid

Verbrauch:

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Abedinia, Oveis, und Nima Amjady. „Short-Term Load Forecast of Electrical Power System by Radial Basis Function Neural Network and New Stochastic Search Algorithm: Load Forecasting“. International Transactions on Electrical Energy Systems 26, Nr. 7 (Juli 2016): 1511– 25.	Australian Energy Market Commission (AEMC), Pennsylvania–New Jersey–Maryland (PJM), North-American electric utilities	Short Term	Temperatur, Luftfeuchtigkeit	KNN
Abu-Shikhah, Nazih, Fawwaz Elkarmi, und Osama M. Aloquili. „Medium-Term Electric Load Forecasting Using Multivariable Linear and Non-Linear Regression“. Smart Grid and Renewable Energy 02, Nr. 02 (2011): 126–35.	Jordaniens Elektrizitätssystem	Mid Term		Multivariable Regression
Ahmadi, Saleh, Hassan Bevrani, und Hannah Jannaty. „A Fuzzy Inference Model for Short-Term Load Forecasting“. In 2012 Second Iranian Conference on Renewable Energy and Distributed Generation, 39–44. Tehran, Iran: IEEE, 2012.	Stromnetz von Sanandaj in Kurdistan im Iran	Short Term	Temperatur, Meteorologische Daten, Kalendereffekte	fuzzy logic

Ahsan, Q., und M. Uddin. „A Probabilistic Approach of Electrical Energy Forecasting“. In 2005 IEEE Instrumentation and Measurement Technology Conference Proceedings, 2:1070–74. Ottawa, ON, Canada: IEEE, 2005.	Stromnetz des Bangladesh Power Development Board	Long Term	Kalendereffekte	Wahrscheinlichkeitsdichtefunktionen von Lastverhältnissen
Ansarimehr, P., S. Barghinia, Z. Mirsepassi, und H. Habibi. „Identification and Modification of Improper Load Data Used in Short-Term Load Forecasting“. In 2005 IEEE Russia Power Tech, 1–5. St. Petersburg, Russia: IEEE, 2005.	Bakhtar Regional Electric Company (Teil des iranischen Stromnetzes)	Short Term	Kalendereffekte, Meteorologische Daten	ANR (absolute normalized residual)
Arfoa, Aouda A. „Long-Term Load Forecasting of Southern Governorates of Jordan Distribution Electric System“. Energy and Power Engineering 07, Nr. 05 (2015): 242–53.	Stromversorgungsgesellschaft verantwortlich für südlichen Teile Jordaniens (Ma'an, Karak und Akaba)	Long Term	Meteorologische und demographische Faktoren	Least squares regression
Cai, Qiuna, Binjie Yan, Binghong Su, Sijie Liu, Mingxu Xiang, Yakun Wen, Yanyu Cheng, und Nan Feng. „Short-term Load Forecasting Method Based on Deep Neural Network with Sample Weights“. International	Lastdaten von Guangdong	Short Term	Temperatur, Luftfeuchtigkeit, Windgeschwindigkeit, Niederschlag, Kalendereffekte	KNN (DNN)

Transactions on Electrical Energy Systems 30, Nr. 5 (Mai 2020).				
Canbing Li, Meiping Fu, Jincheng Shang, und Peng Cheng. „A Novel Probabilistic Short-Term Load Forecasting Method for Large Power Grid“. In 2010 Asia-Pacific Power and Energy Engineering Conference, 1–4. Chengdu: IEEE, 2010.	(Teil-)Stromnetz(e) der Guangdong Provinz in China	Short Term	Meteorologische Daten der Teilnetze	Distributed Algorithm
Cancelo, José Ramón, Antoni Espasa, und Rosmarie Grafe. „Forecasting the Electricity Load from One Day to One Week Ahead for the Spanish System Operator“. International Journal of Forecasting, 2008, 15.	Spanischer Netzbetreiber Red Eléctrica de España	Short Term	Kalendereffekte, meteorologische Daten (Temperatur, Sonnenscheindauer, Bewölkungsgrad)	ARIMA, KNN
Carpinteiro, Otávio A S. „A Hierarchical Self-Organizing Map Model in Short-Term Load Forecasting“, o. J., 9.	Brasilianischen Stromversorgungsunternehmen	Short Term	Kalendereffekte	KNN
Castelli, Mauro, Leonardo Vanneschi, und Matteo De Felice. „Forecasting Short-Term Electricity Consumption Using a Semantics-Based Genetic Programming Framework: The South Italy	TERNA S.p.A. (Rete Elettrica Nazionale; italienischer Stromübertragungsnetzbetreiber), Süditalien	Short Term	Meteorologische Daten (Temperatur, Luftdruck, Windgeschwindigkeit, etc.)	Genetic Programming (AI model)

Case“. Energy Economics 47 (Januar 2015): 37–41.				
Chang, Qicheng, Yishen Wang, Xiao Lu, Di Shi, Haifeng Li, Jiajun Duan, und Zhiwei Wang. „Probabilistic Load Forecasting via Point Forecast Feature Integration“. In 2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), 99–104. Chengdu, China: IEEE, 2019.	ISO New England public dataset [24], including eight sub- load zones (CT, ME, NH, RI, VT, SEMA, WCMA and NEMA) and the total system load	Short Term	Kalendereffekte, meteorologische Daten	KNN, gradient boosting regression
Charlton, Nathaniel, und Colin Singleton. „A Refined Parametric Model for Short Term Load Forecasting“. International Journal of Forecasting 30, Nr. 2 (April 2014): 364–68.		Short Term	Kalendereffekte, Temperatur	multiple linear regression
Chauhan, B.K., A. Sharma, und M. Hanmandlu. „Neuro-Fuzzy Approach Based Short Term Electric Load Forecasting“. In 2005 IEEE/PES Transmission & Distribution Conference & Exposition: Asia and Pacific, 1–5. Dalian, China: IEEE, 2005.	Neo-Pool-Region (Neuengland)	Short Term	Meteorologische Daten (Temperatur), Kalendereffekte	KNN

Chen, Junxingxu, Ting Li, Yanhui Zou, Guorui Wang, Huisheng Ye, und Fengyi Lv. „An Ensemble Feature Selection Method for Short-Term Electrical Load Forecasting“. In 2019 IEEE 3rd Conference on Energy Internet and Energy System Integration (EI2), 1429–32. Changsha, China: IEEE, 2019.	ISO New England Inc., BOS station of Massachusetts	Short Term	Lastverhalten, Kalendereffekte, meteorologische und ökonomische Daten	embedded ensemble feature selection
Chen, B.-J., M.-W. Chang, und C.-J. Lin. „Load Forecasting Using Support Vector Machines: A Study on EUNITE Competition 2001“. IEEE Transactions on Power Systems 19, Nr. 4 (November 2004): 1821–30.		Mid Term	Kalendereffekte, meteorologische Daten (Temperatur)	KNN (SVM)
Cui, Jie, Qiang Gao, und Dahua Li. „Improved Long Short-Term Memory Network Based Short Term Load Forecasting“. In 2019 Chinese Automation Congress (CAC), 4428–33. Hangzhou, China: IEEE, 2019.	Tianjin high-tech zone	Short Term	Kalendereffekte, Temperatur	KNN (LSTM)
Dehalwar, Vasudev, Akhtar Kalam, Mohan Lal Kolhe, und Aladin Zayegh. „Electricity Load Forecasting for Urban Area Using Weather Forecast Information“. In 2016 IEEE	Australian Energy Market Operator	Short Term	Kalendereffekte, meteorologische Daten (Temperatur, Luftfeuchtigkeit)	KNN, Bagged Regression Trees

International Conference on Power and Renewable Energy (ICPRE), 355–59. Shanghai, China: IEEE, 2016.				
Dilhani, M H M R Shyamali, und Chawalit Jeenanunta. „Daily Electric Load Forecasting: Case of Thailand“. In 2016 7th International Conference of Information and Communication Technology for Embedded Systems (IC-ICTES), 25–29. Bangkok, Thailand: IEEE, 2016.	Electricity Generating Authority of Thailand	Short Term	Temperatur	KNN
Ebrahimi, Akbar, und Amir Moshari. „Holidays Short-Term Load Forecasting Using Fuzzy Improved Similar Day Method: HOLIDAYS LOAD FORECASTING FISDM“. International Transactions on Electrical Energy Systems 23, Nr. 8 (November 2013): 1254–71.	Lastdaten von Isfahan, Iran	Short Term	Kalendereffekte	fuzzy expert system
Fan, Guo-Feng, Yan-Hui Guo, Jia-Mei Zheng, und Wei-Chiang Hong. „A Generalized Regression Model Based on Hybrid Empirical Mode Decomposition and Support Vector Regression with Back-propagation Neural Network	Energiemarkt von New South Wales (NSW, Australien)	Mid Term	Kalendereffekte, Temperatur	hybrid empirical mode decomposition and support vector regression with back-propagation neural network, namely the EMDHR-SVR-BPNN model

for Mid-short-term Load Forecasting“. Journal of Forecasting, 3. Februar 2020, for.2655.				
Fan, S., K. Methaprayoon, und W. J. Lee. „Short-Term Multi-Region Load Forecasting Based on Weather and Load Diversity Analysis“. In 2007 39th North American Power Symposium, 562–67. Las Cruces, NM, USA: IEEE, 2007.	Kontrollzone eines Stromversorgungsunternehmens im mittleren Westen der USA (Aufteilung in 24 Regionen)	Short Term	Kalendereffekte, meteorologische Daten (Temperatur, Luftfeuchtigkeit, Windgeschwindigkeit, etc.)	KNN
Fan, Shu, und Rob J Hyndman. „Short-Term Load Forecasting Using Semi-Parametric Additive Models“. In 2011 IEEE Power and Energy Society General Meeting, 1–7. San Diego, CA: IEEE, 2011.	Stromsystem von Australian National Electricity Market (Victorian region)	Short Term	Temperatur, Kalendereffekte	semi-parametric additive model
Fujiwara, Takahiro, und Yuzuru Ueda. „Load Forecasting Method for Commercial Facilities by Determination of Working Time and Considering Weather Information“. In 2018 7th International Conference on Renewable Energy Research and Applications (ICRERA), 336–41. Paris: IEEE, 2018.	2270 kommerziellen Anlagen im Gebiet Kanto in Japan	Short Term	Arbeitszeiten, meteorologische Daten	Clustering

Ghareeb, W. T., und E. F. El Saadany. „A Hybrid Genetic Radial Basis Function Network with Fuzzy Corrector for Short Term Load Forecasting“. In 2013 IEEE Electrical Power & Energy Conference, 1–5. Halifax, NS, Canada: IEEE, 2013.	Ägyptisches Elektrizitätssystem	Short Term	Temperatur	KNN (GARBF)
Göb, Rainer, Kristina Lurz, und Antonio Pievatolo. „Electrical Load Forecasting by Exponential Smoothing with Covariates“. Applied Stochastic Models in Business and Industry 29, Nr. 6 (November 2013): 629–45.	Energieversorger in einigen Provinzen der Emilia-Romagna, Italien	Short Term	Kalendereffekte, Meteorologische Daten (Temperatur, Luftfeuchtigkeit, Bewölkungsgrad, Windgeschwindigkeit)	exponential smoothing with covariates
Goude, Yannig, Raphael Nedellec, und Nicolas Kong. „Local Short and Middle Term Electricity Load Forecasting With Semi-Parametric Additive Models“. IEEE Transactions on Smart Grid 5, Nr. 1 (Januar 2014): 440–46.	2200 Umspannwerke des französischen Verteilungsnetzes	Short Term, Mid Term	Kalendereffekte, Temperatur	semi-parametric model
Grenier, M. „Short-Term Load Forecasting at Hydro-Quebec TransEnergie“. In 2006 IEEE Power Engineering Society General Meeting, 5 pp.	Hydro-Québec (Elektrizitätsversorgung)	Short Term	Kalendereffekte, Wettervariablen, Sonnenwinkel, Temperatur, Bewölkungsgrad, Niederschlag	Regressionsfunktionen

Montreal, Que., Canada: IEEE, 2006.				
Hattab, Mohammed, Mohammed Ma'itah, Tha'er Sweidan, Mohammed Rifai, und Mohammad Momani. „Medium Term Load Forecasting for Jordan Electric Power System Using Particle Swarm Optimization Algorithm Based on Least Square Regression Methods“. Journal of Power and Energy Engineering 05, Nr. 02 (2017): 75–96.	National Electric Power Company NEPCO (Jordanien)	Mid Term		Particle Swarm Optimization, Least Squares
Hippert, H.S., D.W. Bunn, und R.C. Souza. „Large Neural Networks for Electricity Load Forecasting: Are They Overfitted?“ International Journal of Forecasting 21, Nr. 3 (Juli 2005): 425–34.	Lastdaten von Rio de Janeiro, Brasilien	Short Term	Kalendereffekte, Temperatur	KNN
Hui, Xue, Wang Qun, Li Yao, Zhang Yingbin, Shi Lei, und Zhang Zhisheng. „Short-Term Load Forecasting Model Based on Deep Neural Network“. In 2017 2nd International Conference on Power and	Stromversorgungssystem	Short Term		KNN

Renewable Energy (ICPRE), 589–91. Chengdu: IEEE, 2017.				
Huo, Limin, Xinqiao Fan, Yunfang Xie, und Jinliang Yin. „Short-Term Load Forecasting Based on the Method of Genetic Programming“. In 2007 International Conference on Mechatronics and Automation, 839– 43. Harbin, China: IEEE, 2007.	Elektrizitätsgesellschaft des Bezirks	Short Term		Genetic Programming
Imani, Maryam. „Long Short-Term Memory Network and Support Vector Regression for Electrical Load Forecasting“. In 2019 International Conference on Power Generation Systems and Renewable Energy Technologies (PGSRET), 1–6. Istanbul, Turkey: IEEE, 2019.	AMPds-Datensatzes (Almanac of Minutely Power)	Short Term	Kalendereffekte, Temperatur	KNN (SVR, LSTM)
Itagaki, Tadahiro, und Hiroyuki Mori. „Reconstructing Clusters for Preconditioned Short-Term Load Forecasting“. Electrical Engineering in Japan 161, Nr. 1 (Oktober 2007): 26–33.		Short Term	Temperatur, discomfort index, Luftfeuchtigkeit	KNN (RBF), Clustering

Jaber, Aqeel S., Koay A. Satar, und Nadheer A. Shalash. „Short Term Load Forecasting for Electrical Dispatcher of Baghdad City Based on SVM-PSO Method“. In 2018 2nd International Conference on Electrical Engineering and Informatics (Icon EEI), 140–43. Batam, Indonesia: IEEE, 2018.	Lastdaten von Bagdad	Short Term	Kalendereffekte	KNN (PSOSVM),
Jin, Xin, Jie Wu, Yao Dong, und Dezhong Chi. „Application of a Hybrid Model to Short-Term Load Forecasting“. In 2010 International Conference of Information Science and Management Engineering, 492–97. Shaanxi, China: IEEE, 2010.		Short Term		grey forecasting model, SVM
Kazemi, S.M.R., Mir Meisam Seied Hoseini, S. Abbasian-Naghneh, und Seyed Habib A. Rahmati. „An Evolutionary-Based Adaptive NeuroFuzzy Inference System for Intelligent Short-Term Load Forecasting“. International Transactions in Operational Research 21, Nr. 2 (März 2014): 311–26.	Lastdaten im Iran	Short Term		KNN (eneticbased adaptive neurofuzzy inference system/GBAN-FIS)

Khorsheed, Eman. „Long-Term Energy Peak Load Forecasting Models: A Hybrid Statistical Approach“. In 2018 Advances in Science and Engineering Technology International Conferences (ASET), 1–6. Abu Dhabi: IEEE, 2018.	Lastdaten von Bahrain	Long Term	Kalendereffekte, Temperatur, Bevölkerung	multiple regression, machine learning tools
Khuntia, S. R., J. L. Rueda, und M. A. M. M. van der Meijden. „Neural Network-Based Load Forecasting and Error Implication for Short-Term Horizon“. In 2016 International Joint Conference on Neural Networks (IJCNN), 4970–75. Vancouver, BC, Canada: IEEE, 2016.	Unabhängiger USSystembetreiber	Short Term	Kalendereffekte, Verbrauchsverhalten, Meteorologische Daten, Events	KNN
Koo, Bon-gil, Sang-Wook Lee, Wook Kim, und June Ho Park. „Comparative Study of Short-Term Electric Load Forecasting“. In 2014 5th International Conference on Intelligent Systems, Modelling and Simulation, 463–67. Langkawi, Malaysia: IEEE, 2014.	Lastdaten in Korea	Short Term	Kalendereffekt, Meteorologische Daten	KNN (ANN), SES (Simple Exponential Smoothing), GMDH (Group Method of Data handling)

Kurata, Eitaro, und Hiroyuki Mori. „Short-Term Load Forecasting Using Informative Vector Machine“. Electrical Engineering in Japan 166, Nr. 2 (30. Januar 2009): 23–31.		Short Term	Temperatur, Luftfeuchtigkeit, discomfort index	Informative Vector Machine, kernel Machine, Gaussian process
Li, Der-Chiang. „Forecasting Short-Term Electricity Consumption Using the Adaptive Grey-Based Approach—An Asian Case“, 2012, 7.	Asia-Pacific Economic Cooperation (APEC) energy database	Short Term		Grey theory
Li, Z., A.S. Hurn, und A.E. Clements. „Forecasting Quantiles of DayAhead Electricity Load“. Energy Economics 67 (September 2017): 60–71.	Nationales Stromnetz Australiens	Short Term	Kalendereffekte, Temperatur	Bayesian quantile regression
Liu, Song, Yaming Cui, Yaze Ma, und Peng Liu. „Short-Term Load Forecasting Based on GBDT Combinatorial Optimization“. In 2018 2nd IEEE Conference on Energy Internet and Energy System Integration (EI2), 1–5. Beijing: IEEE, 2018.	Lastdaten eines einzelnen Gebietes in Südchina	Short Term	Temperatur, Luftfeuchtigkeit	Gradient Boosting Decision Tree (GBDT)
Lu, Ning, und Jianzhong Zhou. „Particle Swarm Optimization-Based RBF Neural Network Load Forecasting Model“. In 2009 Asia-Pacific Power and	Lastdaten einer Stadt in China	Short Term	Wetterkondition (sonnig, bewölkt, regnerisch)	KNN

Energy Engineering Conference, 1–4. Wuhan, China: IEEE, 2009.				
Ma, Lixin, Youming Ren, Nana Qu, und Ni Jiang. „Short-Term Load Forecasting Based on Complexity Science Theory“. In 2011 International Conference on Electrical and Control Engineering, 1262–1262. Yichang, China: IEEE, 2011.	Energiesystem mit vier Subsystemen und jeweils 16 Teilsystemen	Short Term	Kalendereffekte, Meteorologische Daten	KNN (SVM)
Ma, Yuan, Qian Zhang, Jinjin Ding, Qiongjing Wang, und Jinhui Ma. „Short Term Load Forecasting Based on IForest-LSTM“. In 2019 14th IEEE Conference on Industrial Electronics and Applications (ICIEA), 2278–82. Xi’an, China: IEEE, 2019.	Lastdaten von einem städtischen Energieversorgungsunternehmen	Short Term		KNN (LSTM)
Malki, Heidar A., Nicolaos B. Karayiannis, und Mahesh Balasubramanian. „Short-Term Electric Power Load Forecasting Using Feedforward Neural Networks“. Expert Systems 21, Nr. 3 (Juli 2004): 157–67.	Lastdaten in Berkeley, California	Very Short Term, Short Term	Kalendereffekte, Temperatur, Luftfeuchtigkeit	KNN

Mamlook, Rustum, Omar Badran, und Emad Abdulhadi. „A Fuzzy Inference Model for Short-Term Load Forecasting“. Energy Policy 37, Nr. 4 (April 2009): 1239–48.	Lastdaten von National Electric Power Company (NEPCO) in Jordanien	Short Term	Kalendereffekte, meteorologische Daten (v.a. Temperatur), ökonomische Faktoren (Grad der Industrialisierung, Konsum/Produktion),	Fuzzy sets
Manjhi, Yogesh, und Joydip Dhar. „Forecasting Energy Consumption Using Particle Swarm Optimization and Gravitational Search Algorithm“. In 2016 International Conference on Advanced Communication Control and Computing Technologies (ICACCCT), 417–20. Ramanathapuram, India: IEEE, 2016.		Short Term	Meteorologische Daten (Temperatur, Windgeschwindigkeit, Bewölkungsgrad)	KNN (PSO, GSA)
Mao, Yi, Fan Yang, und Caiping Wang. „Application of BP Network to Short-Term Power Load Forecasting Considering Weather Factor“. In 2011 International Conference on Electric Information and Control Engineering, 172–75. Wuhan, China: IEEE, 2011.	Lastdaten in Hunan, China	Short Term	Meteorologische Daten (Temperatur, Luftfeuchtigkeit, Windgeschwindigkeit)	KNN
Methaprayoon, K., W.J. Lee, S. Rasmiddatta, J. Liao, und R. Ross.	Versorgungsunternehmen, Western Farmers Electric Cooperative	Short Term	Kalendereffekte, Temperatur	KNN

„Multi-Stage Artificial Neural Network Short-Term Load Forecasting Engine with Front-End Weather Forecast“. In 2006 IEEE Industrial and Commercial Power Systems Technical Conference - Conference Record, 1–7. Detroit, MI, USA: IEEE, 2006.				
Mohandes, Mohamed. „Support Vector Machines for Short-Term Electrical Load Forecasting“. International Journal of Energy Research 26, Nr. 4 (25. März 2002): 335–45.	Lastdaten der östlichen Provinz in Saudi-Arabien	Short Term	Kalendereffekte	KNN (SVM)
Mori, Hiroyuki, und Noriyuki Kosemura. „A Data Mining Method for Short-Term Load Forecasting in Power Systems“. Electrical Engineering in Japan 139, Nr. 2 (30. April 2002): 12–22.	Lastdaten von Energiesystemen	Short Term	Kalendereffekte, Temperatur, discomfort index, Luftfeuchtigkeit	KNN (MLP, regression tree)
Mourad, Mordjaoui, Boudjema Bouzid, und Bouabaz Mohamed. „GathGeva Approach to Forecast Electric Energy Consumption“. In 4th International Conference on Power Engineering, Energy and Electrical Drives, 330–33. Istanbul, Turkey: IEEE, 2013.	Lastdaten der RTE Frankreich	Short Term		fuzzy logic clustering

<p>Mukhopadhyay, P., G. Mitra, S. Banerjee, und G. Mukherjee. „Electricity Load Forecasting Using Fuzzy Logic: Short Term Load Forecasting Factoring Weather Parameter“. In 2017 7th International Conference on Power Systems (ICPS), 812–19. Pune: IEEE, 2017.</p>	<p>SCADA-System</p>	<p>Short Term</p>	<p>Temperatur, Luftfeuchtigkeit</p>	<p>fuzzy logic</p>
<p>Musbah, Hmeda, und Mo El-Hawary. „SARIMA Model Forecasting of Short-Term Electrical Load Data Augmented by Fast Fourier Transform Seasonality Detection“. In 2019 IEEE Canadian Conference of Electrical and Computer Engineering (CCECE), 1–4. Edmonton, AB, Canada: IEEE, 2019.</p>		<p>Short Term</p>	<p>Kalendereffekte, meteorologische Daten</p>	<p>ARIMA</p>
<p>Pandey, Anil K., Kishan Bhushan Sahay, M. M. Tripathi, und D. Chandra. „Short-Term Load Forecasting of UPPCL Using ANN“. In 2014 6th IEEE Power India International Conference (PIICON), 1–6. Delhi: IEEE, 2014.</p>	<p>Lastdaten der Uttar Pradesh Power Corporation India ltd.</p>	<p>Short Term</p>	<p>Kalendereffekte</p>	<p>KNN</p>

<p>Peng, Junran, Shengyu Gao, und Anzi Ding. „Study of the Short-Term Electric Load Forecast Based on ANFIS“. In 2017 32nd Youth Academic Annual Conference of Chinese Association of Automation (YAC), 832–36. Hefei, China: IEEE, 2017.</p>	<p>Lastdaten der Ost-Tschechoslowakei</p>	<p>Short Term</p>	<p>Kalendereffekte, meteorologische Daten (Temperatur)</p>	<p>Adaptive network-based fuzzy inference system (ANFIS) model</p>
<p>Qian Zhang, und Tongna Liu. „Application of SVM and Wavelet Neural Network Method for Short-Term Power Load Forecasting“. In 2010 The 2nd International Conference on Computer and Automation Engineering (ICCAE), 412–16. Singapore: IEEE, 2010.</p>	<p>Liaoning Power Network, China</p>	<p>Short Term</p>	<p>Meteorologische Daten</p>	<p>KNN (SVM)</p>
<p>Qiuyu, Lu, Cai Qiuna, Liu Sijie, Yang Yun, Yan Binjie, Wang Yang, und Zhou Xinsheng. „Short-Term Load Forecasting Based on Load Decomposition and Numerical Weather Forecast“. In 2017 IEEE Conference on Energy Internet and Energy System Integration (EI2), 1–5. Beijing: IEEE, 2017.</p>	<p>Lastdaten eines Städtetzes in Südchina</p>	<p>Short Term</p>	<p>Kalendereffekte, meteorologische Daten (Temperatur, Luftfeuchtigkeit, Windgeschwindigkeit)</p>	<p>SVR</p>

Qun, Wang, Zhang Yingbin, Zhu Xinying, Wang Yize, und Zhang Zhisheng. „Short-Term Load Forecasting Model Based on 5idgelet Neural Network Optimized by Particle Swarm Optimization Algorithm“, o. J., 4.		Short Term		KNN
Ramezani, M., H. Falaghi, M.-R. Haghifam, und G.A. Shahryari. „Short-Term Electric Load Forecasting Using Neural Networks“. In EUROCON 2005 - The International Conference on „Computer as a Tool“, 1525–28. Belgrade, Serbia and Montenegro: IEEE, 2005.	Lastdaten aus einem Hoch- und Höchstspannungs-Umspannwerk im Süden des Iran	Short Term	Kalendereffekte, meteorologische Daten (Temperatur)	KNN (MLP)
Ran Li, Jing Hua Li, und He Ming Li. „The Short-Term Electric Load Forecasting Grid Model Based on MDRBR Algorithm“. In 2006 IEEE Power Engineering Society General Meeting, 6 pp. Montreal, Que., Canada: IEEE, 2006.	Lastdaten der folgenden Subnetze: Peking, Tianjin, Tangshan	Short Term	Kalendereffekte, meteorologische Daten (Temperatur, Niederschlag, Luftfeuchtigkeit)	Mining default rules on rough sets (MDRBR) algorithm, multi-layered rule-network
Ren, Yi, Ming Zhou, Gengyin Li, und Zhao Shen. „Hierarchically coordinated ultra-short term load forecasting for load	Large scale Advanced Metering Infrastructure (AMI)	Very Short Term	Kalendereffekte, Temperatur, Niederschlag, historische und aktuelle Wetterdaten, Strompreis	Fuzzy Cmean clustering, KNN, time series method

aggregator“. In 2015 5th International Conference on Electric Utility Deregulation and Restructuring and Power Technologies (DRPT), 141–46. Changsha, China: IEEE, 2015.				
Rivas-Perea, Pablo, Juan Cota-Ruiz, David Garcia Chaparro, Abel Quezada Carreón, Francisco J. Enríquez Aguilera, und Jose-Gerardo Rosiles. „Forecasting the Demand of Short-Term Electric Power Load with Large-Scale LP-SVR“. Smart Grid and Renewable Energy 04, Nr. 06 (2013): 449–57.	Lastdaten von New England Power Pool (NEPOOL)	Short Term	Kalendereffekte, Temperatur	LP-SVR
Sahay, Kishan Bhushan, Suneet Sahu, und Pragya Singh. „Short-Term Load Forecasting of Toronto Canada by Using Different ANN Algorithms“. In 2016 IEEE 6th International Conference on Power Systems (ICPS), 1–6. New Delhi, India: IEEE, 2016.	Lastdaten von Toronto, Kanada	Short Term	Kalendereffekte, Temperatur	KNN
Santos, P. J., A. G. Martins, A. J. Pires, J. F. Martins, und R. V. Mendes. „Short-Term Load Forecast Using Trend Information and Process Reconstruction“. International	Drei Umspannwerke nahe der Stadt Coimbra, Portugal	Short Term	Meteorologische Daten (Temperatur, Luftfeuchtigkeit)	KNN

Journal of Energy Research 30, Nr. 10 (August 2006): 811–22.				
Shu Fan, K. Methaprayoon, und Wei-Jen Lee. „Multiregion Load Forecasting for System With Large Geographical Area“. IEEE Transactions on Industry Applications 45, Nr. 4 (Juli 2009): 1452–59.	Multiregionale Lastdaten eines Stromversorgungsunternehmens im Mittleren Westen der USA	Short Term	Kalendereffekte, meteorologische Daten (v.a. Temperatur)	support vector regression
Shunhua Zhang, Jingjing Lian, Zhiying Zhao, Huijun Xu, und Jing Liu. „Grouping Model Application on Artificial Neural Networks for ShortTerm Load Forecasting“. In 2008 7th World Congress on Intelligent Control and Automation, 6203–6. Chongqing, China: IEEE, 2008.	Lastdaten aus Nanchang city	Short Term	Kalendereffekte, Veranstaltungsdaten, Wetterkondition, Temperatur	KNN
Singh, Astha, und Kishan Bhushan Sahay. „Short-Term Demand Forecasting by Using ANN Algorithms“. In 2018 International Electrical Engineering Congress (IEECON), 1–4. Krabi, Thailand: IEEE, 2018.		Very Short Term	Kalendereffekte, Temperatur	KNN

Soares, Lacir J., und Marcelo C. Medeiros. „Modeling and Forecasting Short-Term Electricity Load: A Comparison of Methods with an Application to Brazilian Data“. International Journal of Forecasting 24, Nr. 4 (Oktober 2008): 630–44.	Lastdaten eines Stromversorgungsunternehmens im Südosten Brasiliens	Short Term	Kalendereffekte	ARIMA
Soares, Lacir Jorge, und Leonardo Rocha Souza. „Forecasting Electricity Demand Using Generalized Long Memory“. International Journal of Forecasting 22, Nr. 1 (Januar 2006): 17–28.	Lastdaten eines Stromversorgungsunternehmens im Südosten Brasiliens	Short Term	Kalendereffekte	long memory (by means of Gegenbauer processes)
Sousa, João C., Humberto M. Jorge, und Luís P. Neves. „Short-Term Load Forecasting Based on Support Vector Regression and Load Profiling: Forecasting Based on Support Vector Regression and Load Profiling“. International Journal of Energy Research 38, Nr. 3 (10. März 2014): 350–62.	Lastdaten von 740 Verbrauchern	Short Term	Kalendereffekte	KNN (SVM)
Tartibu, L K, und K T Kabengele. „Forecasting Net Energy Consumption of South Africa Using Artificial Neural Network“, o. J., 7.	Lastdaten für Südafrika	Long Term	Bevölkerungsgröße, BIP, Wachstumsprognosen, erwarteten Endverbrauchsausgaben der Haushalte (FCEH),	KNN

			relevanten Produktions- und Bergbauindizes	
Trapero, Juan R., und Diego J. Pedregal. „Frequency Domain Methods Applied to Forecasting Electricity Markets“. Energy Economics 31, Nr. 5 (September 2009): 727–35.	Lastdaten des PJM-Marktes (Regional Transmission Organization, USA)	Short Term		Unobserved Components models
Wang, E., T. Galjanic, und R. Johnson. „Short-Term Electric Load Forecasting at Southern California Edison“. In 2012 IEEE Power and Energy Society General Meeting, 1–3. San Diego, CA: IEEE, 2012.	Lastdaten von Southern California Edison's (Stromversorger in den USA)	Short Term		two-stage regression with ARMA
Webberley, Ashton, und David Wenzhong Gao. „Study of Artificial Neural Network Based Short Term Load Forecasting“. In 2013 IEEE Power & Energy Society General Meeting, 1–4. Vancouver, BC: IEEE, 2013.	Global Energy Forecasting Competition 2012	Short Term	Kalendereffekte, Temperatur	KNN
Wei Sun, Jianchang Lu, und Yujun He. „Information Entropy Based	Lastdaten der Provinz Hebei, China	Short Term	Kalendereffekte, meteorologische Daten (Temperatur, Niederschlag, Luftfeuchtigkeit	KNN

Neural Network Model for Short-Term Load Forecasting“. In 2005 IEEE/PES Transmission & Distribution Conference & Exposition: Asia and Pacific, 1–5. Dalian, China: IEEE, 2005.				
Wei Sun, und Yinglian Bai. „Short-Term Load Forecasting Based on Wavelet Transform and BP Neural Network“. In 2011 Second International Conference on Mechanic Automation and Control Engineering, 656–59. Inner Mongolia, China: IEEE, 2011.	Lastdaten von „hebei baoding area“	Short Term		KNN
Wilms, Henning, Marco Cupelli, und Antonello Monti. „Combining Auto-Regression with Exogenous Variables in Sequence-to-Sequence Recurrent Neural Networks for Short-Term Load Forecasting“. In 2018 IEEE 16th International Conference on Industrial Informatics (INDIN), 673–79. Porto: IEEE, 2018.	Global Energy Forecasting Competition 2014	Short Term	Kalendereffekte, Temperatur, Wetterkonditionen	KNN, AR
Xiao, Liye, Wei Shao, Mengxia Yu, Jing Ma, und Congjun Jin. „Research and Application of a Combined Model Based on	Lastdaten aus dem Staat Victoria, dem	Short Term	Kalendereffekte	Combined model, multiobjective flower pollination algorithm

Multi-Objective Optimization for Electrical Load Forecasting“. Energy 119 (Januar 2017): 1057–74.	Staat Queensland, und New South Wales, Australien			
Xiuyun, Gao, Wang Ying, Gao Yang, Sun Chengzhi, Xiang Wen, und Yue Yimiao. „Short-Term Load Forecasting Model of GRU Network Based on Deep Learning Framework“. In 2018 2nd IEEE Conference on Energy Internet and Energy System Integration (EI2), 1–4. Beijing: IEEE, 2018.	Lastdaten einer Region in der Provinz Heilongjiang	Short Term		KNN (GRU, LSTM)
Yahya, Muhammad Amri, Sasongko Pramono Hadi, und Lesnanto Multa Putranto. „Short-Term Electric Load Forecasting Using Recurrent Neural Network (Study Case of Load Forecasting in Central Java and Special Region of Yogyakarta)“. In 2018 4th International Conference on Science and Technology (ICST), 1–6. Yogyakarta: IEEE, 2018.	Lastdaten von Zentral-Java und der Region Yogyakarta	Short Term		KNN
Ye, Shijie, Guangfu Zhu, und Zhi Xiao. „Long Term Load Forecasting and Recommendations for China Based on Support Vector	Lastdaten von China	Long Term	BIP	SVR

Regression“. Energy and Power Engineering 04, Nr. 05 (2012): 380–85.				
Zhao, Wenqing, und Dongxiao Niu. „A Mid-Long Term Load Forecasting Model Based on Improved Grey Theory“. In 2010 2nd IEEE International Conference on Information Management and Engineering, 633– 35. Chengdu, China: IEEE, 2010.	Lastdaten aus Peking, China	Mid Term, Long Term		grey theory model
Zhang Ming-guang, und Li Lin-rong. „Short-Term Load Combined Forecasting Method Based on BPNN and LS-SVM“. In 2011 IEEE Power Engineering and Automation Conference, 319–22. Wuhan, China: IEEE, 2011.	Lastdaten eines Stromversorgungsunternehmens	Short Term		KNN (LS-SVM, BPNN)
Zhang, Yufan, Qian Ai, Zhaoyu Li, Shuangrui Yin, Kaiyi Huang, Muhammad Yousif, und Tianguang Lu. „Data Augmentation Strategy for Small Sample Short-term Load Forecasting of Distribution Transformer“, o. J., 18.	Lastdaten von Verteilungstransformatoren aus Süd- und Ostchina	Short Term	Kalendereffekte, Temperatur, Luftfeuchtigkeit, Wetterindikatoren (sonnig, regnerisch oder bewölkt)	KNN (SVR, GBRT)

Zhang, Zhikun, Canbing Li, Yijia Cao, Liangxing Tang, Junxiong Li, und Bo Wu. „Credibility Assessment of Short-Term Load Forecast in Power System“. In IEEE PES Innovative Smart Grid Technologies, 1–5. Tianjin, China: IEEE, 2012.		Short Term	Kalendereffekte, meteorologische Daten	assessment method
Zhuang, Linlin, Hai Liu, Jimin Zhu, Shulin Wang, und Yong Song. „Comparison of Forecasting Methods for Power System Short-Term Load Forecasting Based on Neural Networks“. In 2016 IEEE International Conference on Information and Automation (ICIA), 114–19. Ningbo, China: IEEE, 2016.	Lastdaten von Weihai, Shandong, China	Short Term	Kalendereffekte,	KNN
Ziel, Florian, und Bidong Liu. „Lasso Estimation for GEFCOM2014 Probabilistic Electric Load Forecasting“. International Journal of Forecasting 32, Nr. 3 (Juli 2016): 1029–37.	Global Energy Forecasting Competition 2014	Short Term	Kalendereffekte, Temperatur	AR
Zivanovic, Rastko. „Local Regression-Based Short-Term Load Forecasting“, o. J., 13.		Short Term	Kalendereffekte, Temperatur	local polynomial regression

Erzeugung:

Windenergie

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Koksoy, Ceyda Er, Mehmet Baris Ozkan, Serkan Buhan, Turan Demirci, Yusuf Arslan, Aysenur Birturk, und Pinar Karagoz. „Improved Wind Power Forecasting Using Combination Methods“. In 2015 IEEE 14th International Conference on Machine Learning and Applications (ICMLA), 1142–47. Miami, FL: IEEE, 2015.	Windkraftmessung durch Wind Power Monitoring and Forecast System for Turkey (RİTM)	Short Term	Windgeschwindigkeit und -richtung	Lp-norm based combination, Fuzzy Soft Sets based combination and treebased combination
Shabbir, Noman, Roya AhmadiAhangar, Lauri Kutt, Muhamamd N. Iqbal, und Argo Rosin. „Forecasting Short Term Wind Energy Generation Using Machine Learning“. In 2019 IEEE 60th International Scientific Conference on Power and Electrical Engineering of Riga Technical University (RTUCON), 1–4. Riga, Latvia: IEEE, 2019.	139 Windturbinen in Estland	Short Term		KNN (SVM)

Erzeugung:

Solarenergie

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Su, Heng-Yi, Tzu-Yi Liu, und Hsu-Hui Hong. „Adaptive Residual Compensation Ensemble Models for Improving Solar Energy Generation Forecasting“. IEEE Transactions on Sustainable Energy 11, Nr. 2 (April 2020): 1103–5.	Global energy forecasting competition 2014, drei Solarzonen			adaptive residual compensation algorithm
Yagli, Gokhan Mert, Dazhi Yang, Dipti Srinivasan, und Monika. „Solar Forecast Reconciliation and Effects of Improved Base Forecasts“. In 2018 IEEE 7th World Conference on Photovoltaic Energy Conversion (WCPEC) (A Joint Conference of 45th IEEE PVSC, 28th PVSEC & 34th EU PVSEC), 2719–23. Waikoloa Village, HI: IEEE, 2018.	318 simulierte PVAnlagen in Kalifornien (Solar Power Data for Integration Studies)		Sonneneinstrahlung	KNN
Yona, A., und T. Senjyu. „One-Day-Ahead 24-Hours Thermal Energy Collection Forecasting Based on Time Series Analysis Technique for Solar Heat Energy Utilization System“. In 2009 Transmission & Distribution		Short Term	Sonneneinstrahlung, Wetterkondition, Temperatur, Luftdruck, Bewölkungsgrad, Windgeschwindigkeit, Niederschlag (Bezug	KNN, treebased model

Conference & Exposition: Asia and Pacific, 1–4. Seoul, South Korea: IEEE, 2009.			auf Naha City, Okinawa Prefecture in Japan)	
---	--	--	---	--

Erzeugung:

Wind- und Solarenergie

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Nagy, Gábor I., Gergő Barta, Sándor Kazi, Gyula Borbély, und Gábor Simon. „GEFCom2014: Probabilistic Solar and Wind Power Forecasting Using a Generalized Additive Tree Ensemble Approach“. International Journal of Forecasting 32, Nr. 3 (Juli 2016): 1087–93.	Zehn verschiedene Windparks, drei Solarparks		Temperatur, Luftfeuchtigkeit, Bewölkungsgrad, Sonneneinstrahlung, Niederschlag, Wassergehalt in der Atmosphäre	quantile regression forest model & a stacked random forest, gradient boosting decision tree model

Erzeugung und Verbrauch:

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
<p>Juban, Romain, Henrik Ohlsson, Mehdi Maasoumy, Louis Poirier, und J. Zico Kolter. „A Multiple Quantile Regression Approach to the Wind, Solar, and Price Tracks of GEFCom2014“. International Journal of Forecasting 32, Nr. 3 (Juli 2016): 1094–1102.</p>		Short Term	<p>Bewölkungsgrad, Luftfeuchtigkeit, Temperatur, Sonneneinstrahlung, Wasser/Eisgehalt der Wolken, Windgeschwindigkeit, Kalendereffekte</p>	multiple quantile regression
<p>Sidorov, Denis, Qing Tao, Ildar Muftahov, Aleksei Zhukov, Dmitriy Karamov, Aliona Dreglea, und Fang Liu. „Energy Balancing Using Charge/Discharge Storages Control and Load Forecasts in a RenewableEnergy-Based Grids“. In 2019 Chinese Control Conference (CCC), 6865–70. Guangzhou, China: IEEE, 2019.</p>	Deutsches Stromnetz	Short Term	Kalendereffekte, Temperatur	<p>deep learning models, random forest, gradient boosting decision trees, support vector machine based regression, multiparametric regression</p>
<p>Wen, Zhe, Yong Li, Yi Tan, Yijia Cao, und Shiming Tian. „A combined forecasting method for renewable generations and loads in power</p>	Lastdaten, Daten der energieerzeugung von PV und	Short Term		KNN (SVM)

systems“. In 2015 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC), 1–5. Brisbane, Australia: IEEE, 2015.	Windkraft in mehreren Quartieren			
Zheng, Ruicheng, Jie Gu, Zhijian Jin, und Hongqiao Peng. „Probabilistic Load Forecasting with High Penetration of Renewable Energy Based on Variable Selection and Residual Modeling“. In 2019 IEEE Power & Energy Society General Meeting (PESGM), 1–5. Atlanta, GA, USA: IEEE, 2019.	Zufällige Daten aus ganz Deutschland (Lasten, PV- und Windenergie)	Short Term	Kalendereffekte, Temperatur, meteorologische Daten	KNN

Strommengenprognose in Microgrid

Verbrauch:

Quartiersebene

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Stadtnetz Ahmed, Mohd. Abdul, K. Shashidhar Reddy, J. Prakash, Abhilash Rai, und B.P. Singh. „Statistical Analysis of Load and Its Frequency Response for Load Forecasting in a Medium Voltage Distribution System“. In 2017 International Conference on Energy, Communication, Data Analytics and Soft Computing (ICECDS), 1146–49. Chennai: IEEE, 2017.	Umspannstation	Short Term	Meteorologische Daten	KNN (BPNN)
Stadtnetz Behera, R., B. P. Panigrahi, und B. B. Pati. „A Hybrid Short Term Load Forecasting Model of an Indian Grid“. Energy and Power Engineering 03, Nr. 02 (2011): 190–93.	Umspannwerk	Short Term	Meteorologische Daten, finanzielles Wachstum der Bevölkerung	KNN (MLP)
Buckler, Jay, Suprio Ray, und Eduardo Castillo-Guerra. „Scalable Local Short-Term Energy Consumption Forecasting“. In 2019 IEEE Canadian Conference of Electrical and Computer	Smart Meter	Short Term		ARIMA

Engineering (CCECE), 1–6. Edmonton, AB, Canada: IEEE, 2019.				
Chan, Patrick P. K., Wei-Chun Chen, Wing W. Y. Ng, und Daniel S. Yeung. „Multiple Classifier System for Short Term Load Forecast of Microgrid“. In 2011 International Conference on Machine Learning and Cybernetics, 1268–73. Guilin, China: IEEE, 2011.	(reale Lastdaten aus Hong Kong)	Short Term	Temperaturtaupunkt, Luftfeuchtigkeit, Druck auf Meereshöhe, Windgeschwindigkeit, Gewitterkodierung, Kalendereffekte	KNN (MLP/RBF)
Fan, Shu, Yuan-Kang Wu, Wei-Jen Lee, und Ching-Yin Lee. „Comparative Study on Load Forecasting Technologies for Different Geographical Distributed Loads“. In 2011 IEEE Power and Energy Society General Meeting, 1–8. San Diego, CA: IEEE, 2011.	Verteiler	Short Term	Meteorologische Daten (v.a. Temperatur)	KNN (vergleichende Studie, dementsprechend liegen mehrere Methoden der KNN vor)
Gao, Rong, und Lefteri H Tsoukalas. „Neural-Wavelet Methodology for Load Forecasting“, o. J., 9.		Short Term	Verbrauchsmuster (Haushalt, Industrie), Kalendereffekte	KNN (MLP)
Keitsch, Krischan, und Thomas Bruckner. „SAWing on Short Term Load Forecasting Errors: Increasing the Accuracy with Self Adaptive Weighting“. In 2016 IEEE Innovative Smart Grid Technologies - Asia (ISGT-Asia),	Smart Meter	Short Term		selfadaptive weighting algorithm (SAW)

1008–13. Melbourne, Australia: IEEE, 2016.				
Kuo, Wen-Chi, Ting-Yen Hsieh, Hsing-Chih Chen, Chang-Liang Chi, und Yung-Fu Huang. „A Novel Framework Short-Term Load Forecasting for Micro-Grid Energy Management System“. In 2018 IEEE International Conference on Smart Energy Grid Engineering (SEGE), 279–83. Oshawa, ON: IEEE, 2018.	Smart Meter	Short Term	Kalendereffekte, Verbrauchsverhalten, meteorologische Faktoren	Exponentielles Glättungsmodell
Leak, Matthew Haslett, Ganesh Kumar Venayagamoorthy, und Paranietharan Arunagirinathan. „Optimal Power Flow in Distribution Scheme Using Load Forecast“. In 2019 IEEE Symposium Series on Computational Intelligence (SSCI), 322–26. Xiamen, China: IEEE, 2019.	Lokaler 12kV Verteiler der Elektrizitätsversorgung, Archive der National Oceanic and Atmospheric Administration von der Wetterstation in Birmingham	Short Term	Meteorologische Daten (Temperatur, Niederschlag), Kalendereffekte	KNN (MLP)
Lekshmi, M, und K. N Adithya Subramanya. „Short-Term Load Forecasting of 400kV Grid Substation Using R-Tool and Study of Influence of Ambient Temperature on the Forecasted Load“. In 2019 Second International Conference on		Short Term	Meteorologische Daten (Temperatur)	ARIMA

Advanced Computational and Communication Paradigms (ICACCP), 1–5. Gangtok, India: IEEE, 2019.				
Liu, Feng, und Zhifang Wang. „Electric Load Forecasting Using Parallel RBF Neural Network“. In 2013 IEEE Global Conference on Signal and Information Processing, 531–34. Austin, TX, USA: IEEE, 2013.	lokales institutionelles Mikrogrid (Versorgungsunternehmen im nationalen Netz des Vereinigten Königreichs)	Short Term	Kalendereffekte	KNN (RBF)
Mitchell, Glen, Sanjay Bahadoorsingh, Neil Ramsamooj, und Chandrabhan Sharma. „A Comparison of Artificial Neural Networks and Support Vector Machines for Short-Term Load Forecasting Using Various Load Types“. In 2017 IEEE Manchester PowerTech, 1–4. Manchester, United Kingdom: IEEE, 2017.	Lastdaten eines Inselstromsystems von Trinidad und Tobago	Short Term	Kalendereffekte	KNN (MLP, SVM)
Niska, Harri, Pekka Koponen, und Antti Mutanen. „Evolving Smart Meter Data Driven Model for Short-Term Forecasting of Electric Loads“. In 2015 IEEE Tenth International Conference on Intelligent Sensors, Sensor Networks and Information Processing (ISSNIP), 1–6. Singapore: IEEE, 2015.	Smart Meter	Short Term	Meteorologische Daten	KNN (MLP)

Otieno, Fred, Nathan Williams, und Patrick McSharry. „Forecasting Energy Demand for Microgrids Over Multiple Horizons“. In 2018 IEEE PES/IAS PowerAfrica, 457–62. Cape Town: IEEE, 2018.	Smart Meter	Mid Term	Temperatur, Niederschlag, Verbrauchsverhalten, Kalendereffekte	Verschiedene Autoregressionen (AR)
Stadtnetz Marinescu, Andrei, Colin Harris, Ivana Dusparic, Vinny Cahill, und Siobhan Clarke. „A Hybrid Approach to Very Small Scale Electrical Demand Forecasting“, 2014, 5.	Smart Meter, Transformator	Short Term	Meteorologische Daten (Temperatur, Luftfeuchtigkeit), Kalendereffekte	KNN (combined methods)
Stadtnetz Panapakidis, Ioannis P., Theodosios Perifanis, und Athanasios S. Dagoumas. „The Effect of Dimensionality Reduction Methods in ShortTerm Load Forecasting Performance“. In 2018 15th International Conference on the European Energy Market (EEM), 1–5. Lodz: IEEE, 2018.	Transformator/Hauptleitung des griechischen Verbundsystems	Short Term	Kalendereffekte, Temperatur	KNN (FFNN)
Stadtnetz Panapakidis, Ioannis P., Nikolaos Skiadopoulos, und Georgios C. Christoforidis. „Forecasting Bus Loads with a Combined Intelligent Prediction System“. In 2018 IEEE International Conference on Environment and Electrical Engineering and 2018 IEEE	Transformator	Short Term	Temperatur, Kalendereffekte	KNN (Clustering & FFNN)

Industrial and Commercial Power Systems Europe (IEEEIC / I&CPS Europe), 1–6. Palermo: IEEE, 2018.				
Panapongpakorn, Tanwalai, und David Banjerdpongchai. „Short-Term Load Forecast for Energy Management Systems Using Time Series Analysis and Neural Network Method with Average True Range“. In 2019 First International Symposium on Instrumentation, Control, Artificial Intelligence, and Robotics (ICA-SYMP), 86–89. Bangkok, Thailand: IEEE, 2019.	Lastdaten aus Mae Hong Son, Thailand	Short Term	Kalendereffekte, Meteorologische Daten (Temperatur, Strahlungsintensität)	KNN (ANN, LSTM, RNN), ARIMA
Raza, Muhammad Qamar, und Abbas Khosravi. „A Review on Artificial Intelligence Based Load Demand Forecasting Techniques for Smart Grid and Buildings“. Renewable and Sustainable Energy Reviews 50 (Oktober 2015): 1352–72.	Smart Grid	Short Term	Meteorologische Daten, Kalendereffekte	KNN (with fuzzy and genetic algorithm, SVM, wavelet and time series, SVM and artificial immune system, genetic algorithm, gradient based learning techniques)
Saad, Z., A. J. Nur Hazirah, A. Suziana, M. A. A. Azhar, Z. Yaacob, F. Ahmad, und M. A. Yusnita. „Short-Term Load Forecasting of 415V, 11kV and 33kV Electrical Systems Using MLP Network“. In 2017 International Conference on	Netzspannung (415V, 11kV, 33kV)	Short Term		KNN (MLP)

Robotics, Automation and Sciences (ICORAS), 1–5. Melaka: IEEE, 2017.				
Sano, Tsuneyo, Itsuko Tezuka, und Yoshihiro Fukuda. „The Load Forecasting Technology in the Electric Power Distribution System“. Electrical Engineering in Japan 153, Nr. 2 (15. November 2005): 14– 27.	Verteiler	Short Term		multiple regression analysis
Scholz, Daniel, und Felix Musgens. „How to Improve Standard Load Profiles: Updating, Regionalization and Smart Meter Data“. In 2017 14th International Conference on the European Energy Market (EEM), 1–6. Dresden, Germany: IEEE, 2017.	Smart Meter	Short Term	Kalendereffekte	Standard load profiles (SLPs)
Sun, Xiaokui, und Zhiyou Ouyang. o. J., -> siehe Quelle für Zitation		Short Term	Temperatur	MLR
Yan, Gangui, Tianyi Han, Wei Zhang, und Shujian Zhao. „Short-Term Load Forecasting of Smart Grid Based on Load Spatial-Temporal Distribution“. In 2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), 781–85. Chengdu, China: IEEE, 2019.	Smart Grid	Short Term		KNN (LSTM)

<p>Yang, Haoyan, Jun Long, Penghui He, und Yuqi Zheng. „Short-Term Load Forecasting of Microgrid Based on Grey Correlation Analysis and Neural Network Optimized by Mind Evolutionary Algorithm“. In 2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), 2738–42. Chengdu, China: IEEE, 2019.</p>		Short Term	Meteorologische Daten, Kalendereffekte	KNN (grey correlation analysis and back propagation neural network optimized by mind evolutionary algorithm /GCA-MEABP)
<p>Yapeng, Yao, Liu Chongxin, Hu Xiaoyu, Liu Hang, Xu Wenwen, Qu Yajun, und Sun Zhenquan. „Probe into Micro-Grid Short-Term Load Forecasting Based on Method of Chaotic Time Series“. In 2017 China International Electrical and Energy Conference (CIEEC), 423–28. Beijing: IEEE, 2017.</p>		Short Term	Temperatur, Klima	chaos prediction model
<p>Cheah, P. H., Gooi, H. B., & Soo, F. L. (2011, June). Quarter-hourahead load forecasting for microgrid energy management system. In <i>2011 IEEE Trondheim PowerTech</i> (pp. 1-6). IEEE.</p>	Energy Market Company (EMC) in Singapur	Short Term		KNN (BP. MLP)

Haushaltsebene (betrifft teils mehrere Haushalte gleichzeitig)

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Ahmed, K.M.U., M.A. Al Amin, und M.T. Rahman. „Application of Short Term Energy Consumption Forecasting for Household Energy Management System“. In 2015 3rd International Conference on Green Energy and Technology (ICGET), 1–6. Dhaka, Bangladesh: IEEE, 2015.	28 Haushalte in Bangladeshi	Short Term	Kalendereffekt	KNN (FFNN)
Amin, M. Abdullah Al, und Md. Ashraful Hoque. „Comparison of ARIMA and SVM for Short-Term Load Forecasting“. In 2019 9th Annual Information Technology, Electromechanical Engineering and Microelectronics Conference (IEMECON), 1–6. Jaipur, India: IEEE, 2019.		Short Term	Kalendereffekt	KNN (SVM & ARIMA)
Arora, Siddharth, und James W. Taylor. „Forecasting Electricity Smart Meter Data Using Conditional Kernel Density Estimation“. Omega 59 (März 2016): 47–59.	Smart Meter	Short Term	Kalendereffekt	CKD (conditional kernel density)

Ebrahim, Ahmed F., und Osama A. Mohammed. „Energy Disaggregation Based Deep Learning Techniques: A Pre-Processing Stage to Enhance The Household Load Forecasting“. In 2018 IEEE Industry Applications Society Annual Meeting (IAS), 1–8. Portland.	Smart Meter	Short Term		KNN (FFNN)
Ghofrani, M., M. Hassanzadeh, M. Etezadi-Amoli, und M. S. Fadali. „Smart Meter Based Short-Term Load Forecasting for Residential Customers“. In 2011 North American Power Symposium, 1–5. Boston, MA, USA: IEEE, 2011.	Smart Meter	Short Term	Meteorologische Daten, Verbrauchverhalten	Kalman filtering
Goehry, Benjamin, Yannig Goude, Pascal Massart, und Jean-Michel Poggi. „Aggregation of Multi-Scale Experts for Bottom-Up Load Forecasting“. IEEE Transactions on Smart Grid 11, Nr. 3 (Mai 2020): 1895–1904.	Smart Meter	Short Term	Meteorologische Daten (Temperatur)	Clusteranalyse
Heghedus, Cristina, Antorweep Chakravorty, und Chunming Rong. „Energy Load Forecasting Using Deep Learning“. In 2018 IEEE International Conference on Energy Internet (ICEI), 146–51. Beijing, China: IEEE, 2018.	Smart Meter	Short Term	Kalendereffekte, Meteorologische Daten, Informationen zu den einzelnen Verbrauchern (Größe und Lage des Hauses, Anzahl der Mitbewohner, Koch- und Heizmöglichkeiten, Wohlstand)	KNN (GRU (Gated Recurrent Unit) based resursive Deep Learning)

Imani, Maryam, und Hassan Ghassemian. „Electrical Load Forecasting Using Customers Clustering and Smart Meters in Internet of Things“. In 2018 9th International Symposium on Telecommunications (IST), 113–17. Tehran, Iran: IEEE, 2018.	Smart Meter	Short Term	Kalendereffekte	KNN (MLP)
Khan, Zafar A., und Dilan Jayaweera. „Approach for Forecasting Smart Customer Demand with Significant Energy Demand Variability“. In 2018 1st International Conference on Power, Energy and Smart Grid (ICPESG), 1–5. Mirpur Azad Kashmir: IEEE, 2018.	Smart Meter	Short Term	Meteorologische Daten (Temperatur), Kalendereffekte	k-means clustering approach
Kong, Weicong, Zhao Yang Dong, David J. Hill, Fengji Luo, und Yan Xu. „Short-Term Residential Load Forecasting Based on Resident Behaviour Learning“. IEEE Transactions on Power Systems 33, Nr. 1 (Januar 2018): 1087–88.	Zähler eines kanadischen Haushaltes und seiner 19 elektronischen Geräte	Short Term	Kalendereffekt	KNN (LSTM)
Kong, Weicong, Zhao Yang Dong, Youwei Jia, David J. Hill, Yan Xu, und Yuan Zhang. „Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network“. IEEE Transactions on Smart Grid 10, Nr. 1 (Januar 2019): 841–51.	Smart Meter	Short Term		KNN (LSTM)

<p>Koponen, Pekka. „Short-Term Load Forecasting Model Based on Smart Metering Data: Daily Energy Prediction Using Physically Based Component Model Structure“. In 2012 International Conference on Smart Grid Technology, Economics and Policies (SG-TEP), 1–4. Nuremberg, Germany: IEEE, 2012.</p>	<p>Smart Meter</p>	<p>Short Term</p>	<p>Temperatur, Kalendereffekt (Variation der Tageslänge)</p>	<p>Lineare Funktion</p>
<p>Marzooghi, H., K. Emami, P. J. Wolfs, und B. Holcombe. „Short-Term Electric Load Forecasting in Microgrids: Issues and Challenges“. In 2018 Australasian Universities Power Engineering Conference (AUPEC), 1–6. Auckland, New Zealand: IEEE, 2018.</p>	<p>Zähler von 300 Verbrauchern</p>	<p>Short Term</p>	<p>Meteorologische Daten, Kalendereffekte</p>	<p>KNN (WNN), ARIMA</p>
<p>Quilumba, Franklin L., Wei-Jen Lee, Heng Huang, David Y. Wang, und Robert Szabados. „An Overview of AMI Data Preprocessing to Enhance the Performance of Load Forecasting“. In 2014 IEEE Industry Application Society Annual Meeting, 1–7. Vancouver, BC, Canada: IEEE, 2014.</p>	<p>Smart Meter</p>	<p>Short Term</p>	<p>Verbrauchsverhalten</p>	<p>Clusteranalyse</p>

<p>Quilumba, Franklin L., Wei-Jen Lee, Heng Huang, David Y. Wang, und Robert L. Szabados. „Using Smart Meter Data to Improve the Accuracy of Intraday Load Forecasting Considering Customer Behavior Similarities“. IEEE Transactions on Smart Grid 6, Nr. 2 (März 2015): 911–18.</p>	<p>Smart Meter</p>	<p>Short Term</p>	<p>Verbrauchsverhalten</p>	<p>KNN (MLP), Clusteranalyse</p>
<p>Reddy, Sannihith, Yasasvi Neppalli, und K. Sireesha. „Load Optimization and Forecasting for Microgrids“. In 2018 Second International Conference on Intelligent Computing and Control Systems (ICICCS), 1106–12. Madurai, India: IEEE, 2018.</p>	<p>smart modules</p>	<p>Short Term</p>	<p>u.a. Temperatur, Luftfeuchtigkeit</p>	<p>multiple regression model</p>
<p>Yildiz, Baran, Jose I. Bilbao, Jonathon Dore, und Alistair Sproul. „Household Electricity Load Forecasting Using Historical Smart Meter Data with Clustering and Classification Techniques“. In 2018 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), 873–79. Singapore: IEEE, 2018.</p>	<p>Smart Meter</p>	<p>Short Term</p>	<p>Meteorologische Daten, Kalendereffekte</p>	<p>KNN (ANN-E, SVR, LS-SVR), Clusteranalyse</p>

Gebäude(komplex)ebene

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Akarslan, Emre, und Fatih Onur Hocaoglu. „Electricity Demand Forecasting of a Micro Grid Using ANN“. In 2018 9th International Renewable Energy Congress (IREC), 1–5. Hammamet: IEEE, 2018.	Gesamte ANS Campus area of the Afyon Kocatepe University	Short Term	Vielzahl von meteorologischen Echtzeitfaktoren wie Temperatur, Feuchtigkeit, Windgeschwindigkeit, Luftdruck und Sichtweite	KNN (MLP)
Almalaq, Abdulaziz, und George Edwards. „Comparison of Recursive and Non-Recursive ANNs in Energy Consumption Forecasting in Buildings“. In 2019 IEEE Green Technologies Conference(GreenTech), 1–5. Lafayette, LA, USA: IEEE, 2019.	Zähler von Wohn- und Geschäftsgebäuden	Short Term, Mid Term		KNN (LSTM, GRU)
Gulin, Marko, Mario Vasak, Goran Banjac, und Tomislav Tomisa. „Load Forecast of a University Building for Application in Microgrid Power Flow Optimization“. In 2014 IEEE International Energy Conference (ENERGYCON), 1223–27. Cavtat, Croatia: IEEE, 2014.	Fakultät für Elektrotechnik und Informatik der Universität Zagreb	Short Term	Meteorologische Daten	KNN (MLP)

<p>Hida, Yusuke, Ryuichi Yokoyama, Kenji Iba, Kouji Tanaka, und Kuniaki Yabe. „Load Forecasting on Demand Side by Multi-Regression Model for Operation of Battery Energy Storage System“, o. J., 5. Microgrid, V</p>	<p>Meisei Universitätscampus mit einem Battery-Energy-Storage-System</p>	<p>Short Term</p>	<p>Kalendereffekte, Temperatur</p>	<p>Multi Regression Model</p>
<p>Jozi, Aria, Tiago Pinto, Isabel Praca, und Zita Vale. „Day-Ahead Forecasting Approach for Energy Consumption of an Office Building Using Support Vector Machines“. In 2018 IEEE Symposium Series on Computational Intelligence (SSCI), 1620–25. Bangalore, India: IEEE, 2018.</p>	<p>Mehrere Gebäude auf dem Campus der Fakultät für Ingenieurwesen des Polytechnikums von Porto</p>	<p>Short Term</p>	<p>Sonneneinstrahlung, Temperatur</p>	<p>KNN (SVM)</p>
<p>Li, Dan, Haojing Wang, Yu Zhang, und Chen Fang. „Power Grid Load State Information Perception Forecasting Technology for Battery Energy Storage System Based on Elman Neural Network“. In 2019 IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC), 914–17. Chengdu, China: IEEE, 2019.</p>	<p>Stromnetz eines Industrieparks in Tianjin, China</p>			<p>KNN (Elman neural network)</p>

Lim, Jong-Hun, Oh-Sung Kwon, Kyung-Bin Song, und Jeong-Do Park. „Short-Term Load Forecasting for Educational Buildings with Temperature Correlation“. In 4th International Conference on Power Engineering, Energy and Electrical Drives, 405–8. Istanbul, Turkey: IEEE, 2013.	Universitätscampus in Seoul	Short Term	Temperatur	Korrelationsanalyse
Mehdipour Pirbazari, Aida, Mina Farmanbar, Antorweep Chakravorty, und Chunming Rong. „Short-Term Load Forecasting Using Smart Meter Data: A Generalization Analysis“. Processes 8, Nr. 4 (21. April 2020): 484.	Smart Meter	Short Term	Temperatur, Kalendereffekte, Verbrauchsverhalten, Haushaltsausstattung	KNN (SVR, gradien boosted regression tree, FFNN, LSTM)
Nepal, Bishnu, Motoi Yamaha, Aya Yokoe, und Toshiya Yamaji. „Electricity Load Forecasting Using Clustering and ARIMA Model for Energy Management in Buildings“. Japan Architectural Review 3, Nr. 1 (Januar 2020): 62–76.	Building Energy Management System (BEMS)	Short Term	Kalendereffekte	ARIMA, Clusteranalyse
Ours, Andrew Scott, Nabil Nassif, und Darrion Long. „Forecasting Savings of Building Energy Systems Using Artificial Neural Networks“. In 2016 Future Technologies Conference (FTC),	Smart Meter eines Gebäudes	Short Term	Meteorologische Daten (v.a. Trocken- und Feuchtkugeltemperaturen)	KNN (MFNN)

862–67. San Francisco, CA, USA: IEEE, 2016.				
Subbayya, S., J. G. Jetcheva, und Wei-Peng Chen. „Model Selection Criteria for Short-Term Microgrid-Scale Electricity Load Forecasts“. In 2013 IEEE PES Innovative Smart Grid Technologies Conference (ISGT), 1–6. Washington, DC: IEEE, 2013.	Zähler von sechs Gebäuden	Short Term	Meteorologische Daten, Kalendereffekte	MLR, ARIMA
Tan, Wenting, Anan Zhang, Yating Feng, Yangfan Sun, Huang huang, und Wang Siyuan. „Study on Short-Term Load Forecasting Method Considering Meteorological Factors of Offshore Oilfield Group Microgrid“. In 2019 IEEE Innovative Smart Grid Technologies - Asia (ISGT Asia), 850–53. Chengdu, China: IEEE, 2019.	Offshore-Ölfeldgruppe im BohaiMeer	Short Term	Meteorologische Daten (Temperatur, Feuchtigkeit und Windgeschwindigkeit)	KNN (SVM)
Vats, Vibhas Kumar, Sneha Rai, Dibya Bharti, und Mala De. „Very Short-Term and Mid-Term Load Forecasting for Residential Academic Institute: A Case Study“. In 2018 4th International Conference on Computing Communication and	Smartmeter des NITCampus Patna	Very Short Term, Short Term, Mid Term	Kalendereffekte	Lineare Regression

Automation (ICCCA), 1–6. Greater Noida, India: IEEE, 2018.				
Xu, Fang-Yuan, M. C. Leung, und Long Zhou. „A RBF Network for Short — Term Load Forecast on Microgrid“. In 2010 International Conference on Machine Learning and Cybernetics, 3195–99. Qingdao, China: IEEE, 2010.	Stromverteilung eines Chillar-Systems in einem Gebäude in Hongkong	Short Term	Komforteinflussfaktoren (Temperatur, relative Luftfeuchtigkeit, Wochentagseigenschaft)	KNN (RBF/MLP)
Yao, Qi, Xiangping Meng, Hui Wang, und Yinping An. „Short-Term Load Forecasting of Office Building Microgrid Based on EA-NN“. In 2019 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS), 408–12. Shenyang, China: IEEE, 2019.	Bürogebäude einer Universität	Short Term		KNN (MLP)
Yu, Jungwon, Hansoo Lee, Yeongsang Jeong, und Sungshin Kim. „Short-Term Hourly Load Forecasting Using PSO-Based AR Model“. In 2014 Joint 7th International Conference on Soft Computing and	Lastdaten einer Universität und apartment aus Südkorea	Short Term	Kalendereffekte, meteorologische Daten	AR/PSO

Intelligent Systems (SCIS) and 15th International Symposium on Advanced Intelligent Systems (ISIS), 1449–53. Kita-Kyushu, Japan: IEEE, 2014.			(Temperatur, Luftfeuchtigkeit, etc.)	
Yu, Xiaotong, Zhezhuang Xu, Xin Zhou, Jiejun Zheng, Yuxiong Xia, Larry Lin, und Shih-Hau Fang. „Load Forecasting Based on Smart Meter Data and Gradient Boosting Decision Tree“. In 2019 Chinese Automation Congress (CAC), 4438–42. Hangzhou, China: IEEE, 2019.	Smart Meter	Short Term	Kalendereffekte	KNN (gradient boosting decision tree)

Geräteebene

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Liao, Gwo-Ching. „Application a Novel Evolutionary Computation Algorithm for Load Forecasting of Air Conditioning“. In 2012 AsiaPacific Power and Energy Engineering Conference, 1–4. Shanghai, China: IEEE, 2012.	Lastprognose von Klimaanlage	Short Term	Innen- und Außentemperatur, meteorologische Daten, Kalendereffekte	KNN (WNN)

<p>Ploysuwan, Tuchsanai. „Deep CNN & LSTM Network for Appliances Energy Forecasting in Residential Houses Using IoT Sensors“. In 2019 7th International Electrical Engineering Congress (IEECON), 1–4. Hua Hin, Thailand: IEEE, 2019.</p>	<p>IoT-Sensoren</p>		<p>Haustemperatur, relative Luftfeuchtigkeit, -druck, Windgeschwindigkeit, usw.</p>	<p>KNN (CNN & LSTM)</p>
<p>Wang, Shijun, Guobin Xue, Chang Ping, Dinggang Wang, Feng You, und Tao Jiang. „The Application of Forecasting Algorithms on Electric Vehicle Power Load“. In 2018 IEEE International Conference on Mechatronics and Automation (ICMA), 1371–75. Changchun: IEEE, 2018.</p>	<p>ElektrofahrzeugLadestationen</p>	<p>Short Term</p>		<p>Autoregression (ARA)/ KNN (BPA)</p>
<p>Wang, Wenbiao, Chuanjin Li, und Siyuan Wang. „Big Data Used in Energy Efficiency and Load Forecasting of Heating Boilers“. In 2017 36th Chinese Control Conference (CCC), 5638–41. Dalian: IEEE, 2017.</p>	<p>boiler information management platform</p>		<p>Außentemperatur, Auslastung des Heizkessels</p>	<p>Clusteranalyse/ Big Data analyses</p>

Erzeugung

Windenergie

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Aula, Fadhil T., und Samuel C. Lee. „Grid Power Optimization Based on Adapting Load Forecasting and Weather Forecasting for System Which Involves Wind Power Systems“. <i>Smart Grid and Renewable Energy</i> 03, Nr. 02 (2012): 112–18.	SACADA System (Status aller Kraftwerke)	Short Term	Meteorologische Daten (v.a. Windgeschwindigkeit), Kalendereffekte	KNN (MLP)
Forbes, Kevin F., und Ernest M. Zampelli. „The Accuracy of Wind Energy Forecasts and Prospects for Improvement“. In <i>2017 14th International Conference on the European Energy Market (EEM)</i> , 1–6. Dresden, Germany: IEEE, 2017.	50Hertz electricity control area	Short Term	Meteorologische Daten (Windgeschwindigkeit, Temperatur, Luftfeuchtigkeit, Taupunkt)	ARCH/ARMAX model
Hanada, Kazuma, Takataro Hamajima, Makoto Tsuda, Daisuke Miyagi, Takakazu Shintomi, Tomoaki Takao, Yasuhiro Makida, und Masataka Kajiwara. „Wind Power Forecasting Using an Artificial Neural Network for ASPCS“. <i>Energy and Power</i>	Windkraftanlage mit einer Nennleistung von 5 MW	Very Short Term		KNN (MLP), Clusteranalyse (k-means Method)

Engineering 05, Nr. 04 (2013): 414–17.				
Johnson, Peter L., Michael Negnevitsky, und Kashem M. Muttaqi. „Short Term Wind Power Forecasting Using Adaptive Neuro-Fuzzy Inference Systems“. In 2007 Australasian Universities Power Engineering Conference, 1–6. Perth, Australia: IEEE, 2007.	Windparks	Very Short Term	Meteorologische Daten (v.a. Windgeschwindigkeit)	KNN (ANFIS)
Jursa, René, und Kurt Rohrig. „Short-Term Wind Power Forecasting Using Evolutionary Algorithms for the Automated Specification of Artificial Intelligence Models“. International Journal of Forecasting 24, Nr. 4 (Oktober 2008): 694–709.	Windparks (unterschiedliche Standorte in Deutschland)	Very Short Term	Meteorologische Daten (v.a. Windgeschwindigkeit)	KNN (MLP), NNS, automated specification method
Liu, Meng, Franklin L. Quilumba, und Wei-Jen Lee. „Dispatch Scheduling for a Wind Farm with Hybrid Energy Storage Based on Wind and LMP Forecasting“. In 2014 IEEE Industry Application Society Annual Meeting, 1–8. Vancouver, BC, Canada: IEEE, 2014.	Windpark mit einem Energiespeichersystem	Short Term	Meteorologische Daten (Temperatur, Luftdruck, Windrichtung und -geschwindigkeit, Luftfeuchtigkeit)	KNN (MLP)

Mahmoudi, Javad, Majid Jamil, und Hossein Balaghi. „Short and MidTerm Wind Power Plants Forecasting with ANN“. In 2012 Second Iranian Conference on Renewable Energy and Distributed Generation, 167–71. Tehran, Iran: IEEE, 2012.	Windpark	Very Short Term, Short Term	Windgeschwindigkeit, Temperatur	KNN (MLP)
Mahoney, William P., Keith Parks, Gerry Wiener, Yubao Liu, William L. Myers, Juanzhen Sun, Luca Delle Monache, Thomas Hopson, David Johnson, und Sue Ellen Haupt. „A Wind Power Forecasting System to Optimize Grid Integration“. IEEE Transactions on Sustainable Energy 3, Nr. 4 (Oktober 2012): 670–82.	National Center for Atmospheric Research (NCAR) has collaborated with Xcel Energy/ mehrere Windparks	Short Term	Windgeschwindigkeit, Temperatur, Luftfeuchtigkeit	Analogue Ensemble Kalman Filter, Quantile Regression
Mangalova, E., und E. Agafonov. „Wind Power Forecasting Using the K-Nearest Neighbors Algorithm“. International Journal of Forecasting 30, Nr. 2 (April 2014): 402–6.	Windpark		zonale und meridionale Windkomponenten, Windrichtung, Windgeschwindigkeit	Regression tree
Mangalova, Ekaterina, und Olesya Shesterneva. „K-Nearest Neighbors for GEFCom2014 Probabilistic Wind Power Forecasting“. International Journal of Forecasting 32, Nr. 3 (Juli 2016): 1067–73.	Global Energy Forecasting Competition 2014, Daten einzelner Windparks		Windgeschwindigkeit, richtung	k-nearest neighbors algorithm

Men, Zhongxian, Eugene Yee, Fue-Sang Lien, Hua Ji, und Yongqian Liu. „Bootstrapped Multi-Model Neural-Network Super-Ensembles for Wind Speed and Power Forecasting“. Energy and Power Engineering 06, Nr. 11 (2014): 340–48.	Windpark	Short Term	Windgeschwindigkeit	KNN (MLP)
Sánchez, Ismael. „Short-Term Prediction of Wind Energy Production“. International Journal of Forecasting 22, Nr. 1 (Januar 2006): 43–56.	Windpark	Short Term	Windgeschwindigkeit und -richtung	Nonparametric regression
Sánchez, Ismael. „Adaptive Combination of Forecasts with Application to Wind Energy“. International Journal of Forecasting 24, Nr. 4 (Oktober 2008): 679–93.	Zwei Windparks	Short Term	Windgeschwindigkeit und -richtung	adaptive estimation methods (kovarianzbasierte Methode)
Shi, Jie, Yulei Gong, Xiaofei Liu, und Xiaoxun Zhu. „Model Optimization for Very-Short-Term Wind Power Forecasting Using HilbertHuang Transform“. In 2016 International Conference on Smart Grid and Clean Energy Technologies (ICSGCE), 239–43. Chengdu, China: IEEE, 2016.	Windpark	Very Short Term		AR, HHT (Hilbert-Huang-Transformation)
Tan, K. H., T. Logenthiran, und W. L. Woo. „Forecasting of Wind Energy Generation Using Self-Organizing Maps and Extreme		Very Short Term, Short Term	Windgeschwindigkeit und -richtung	KNN (SOM & ELM)

Learning Machines“. In 2016 IEEE Region 10 Conference (TENCON), 451–54. Singapore: IEEE, 2016.				
Varanasi, Jyothi, und M.M. Tripathi. „Artificial Neural Network Based Wind Speed & Power Forecasting in US Wind Energy Farms“. In 2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES), 1–6. Delhi, India: IEEE, 2016.	Mehrere Windparks	Short Term	Meteorologische Daten (v.a. Windgeschwindigkeit)	KNN (MLP)
Wasilewski, J., und D. Baczynski. „Short-Term Electric Energy Production Forecasting at Wind Power Plants in Pareto-Optimality Context“. Renewable and Sustainable Energy Reviews 69 (März 2017): 177–87.	Zwei Windparks (SACADA System)	Very Short Term, Short Term	Meteorologische Daten (v.a. Windgeschwindigkeit)	KNN (MLP)
Yan, Jie, Hao Zhang, Yongqian Liu, Shuang Han, Li Li, und Zongxiang Lu. „Forecasting the High Penetration of Wind Power on Multiple Scales Using Multi-to-Multi Mapping“. IEEE Transactions on Power Systems 33, Nr. 3 (Mai 2018): 3276–84.	Verschiedenen Windparks einer Region (SACADA System)	Short Term	Meteorologische Daten (v.a. Windgeschwindigkeit und -richtung)	Multi-to-Multi Mapping Based on SDAE
Yona, Atsushi, Tomonobu Senjyu, Funabashi Toshihisa, und ChulHwan Kim. „Very Short-Term Generating Power Forecasting for		Very Short Term	Windgeschwindigkeit	KNN (FFNN), AR, KF (Kalman Filter)

Wind Power Generators Based on Time Series Analysis“. Smart Grid and Renewable Energy 04, Nr. 02 (2013): 181–86.				
Zhang, Yao, und Jianxue Wang. „K-Nearest Neighbors and a Kernel Density Estimator for GEFCom2014 Probabilistic Wind Power Forecasting“. International Journal of Forecasting 32, Nr. 3 (Juli 2016): 1074-80.	Global Energy Forecasting Competition 2014, Daten einzelner Windparks	Short Term	Windgeschwindigkeit, - richtung	k-nearest neighbors algorithm, kernel density estimator method
Zhou, Zhenyu, Fei Xiong, Biyao Huang, Chen Xu, Runhai Jiao, Bin Liao, Zhongdong Yin, und Jianqi Li. „Game-Theoretical Energy	Mehrere Windturbinen	Short Term		KNN (SAE)
Management for Energy Internet With Big Data-Based Renewable Power Forecasting“. IEEE Access 5 (2017): 5731–46.				

Solarenergie/Photovoltaik

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Almazrouei, Sumayya, Abdul-Kadir Hamid, und Mohammad Shamsuzzaman. „Predictive Energy Management in Large-Scale Grid Connected PV-	1-MW-PV-System und an das Netz angeschlossene 1-MW-Lithium-Ionen-Batterien-System	Very Short Term	Kalendereffekte, Temperatur, Luftfeuchtigkeit, Windgeschwindigkeit, Sonneneinstrahlung	KNN (MLP)

Batteries System“. In 2018 5th International Conference on Renewable Energy: Generation and Applications (ICREGA), 315–18. Al Ain: IEEE, 2018.				
Barbieri, Florian, Sumedha Rajakaruna, und Arindam Ghosh. „Very Short-Term Photovoltaic Power Forecasting with Cloud Modeling: A Review“. Renewable and Sustainable Energy Reviews 75 (August 2017): 242–63.	PV-Farm	Very Short Term	Grad der Bewölkung	KNN (MLP), ARIMA, Hybride Modelle
Chugh, Ayushi, Priyanka Chaudhary, und M. Rizwan. „Fuzzy Logic Approach for Short Term Solar Energy Forecasting“. In 2015 Annual IEEE India Conference (INDICON), 1–6. New Delhi, India: IEEE, 2015.		Very Short Term, Mid Term	Sonneneinstrahlung (W/M ²)	Fuzzy logic
Do, Thai Phuong, Franck Bourry, und Xavier Le Pivert. „Assessment of Storage and Photovoltaic Short-Term Forecast Contribution to off-Grid Microgrid Operation“. In 2017 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), 1–5. Torino, Italy: IEEE, 2017.	EMS (Energiemanagementsystem)	Short Term	Meteorologische Daten (Grad der Bewölkung)	

Dolara, A., S. Leva, M. Mussetta, und E. Ogliari. „PV Hourly DayAhead Power Forecasting in a Micro Grid Context“. In 2016 IEEE 16th International Conference on Environment and Electrical Engineering (EEEIC), 1–5. Florence, Italy: IEEE, 2016.	PV-Anlagen an vier verschiedenen Standorten	Short Term	Grad der Bewölkung, Meteorologische Daten (Windrichtung, Luftdruck, rel. Luftfeuchtigkeit, Niederschlag, Windgeschwindigkeit, Temperatur, Sonneneinstrahlung)	KNN (PHANN – Physic Hybrid Artificial Neural Network/ MLP)
Huang, Jing, und Matthew Perry. „A Semi-Empirical Approach Using Gradient Boosting and k - Nearest Neighbors Regression for GEFCom2014 Probabilistic Solar Power Forecasting“. International Journal of Forecasting 32, Nr. 3 (Juli 2016): 1081–86.	Drei Solarparks	Short Term	Meteorologische Daten (Wassergehalt der Wolken, Lufttemperatur, rel. Luftfeuchtigkeit, Windgeschwindigkeit, Sonneneinstrahlung)	Gradient boosting, k-nearest neighbors regression
Lee, Munsu, Wonjun Lee, und Jaesung Jung. „24-Hour Photovoltaic Generation Forecasting Using Combined Very-Short-Term and ShortTerm Multivariate Time Series Model“. In 2017 IEEE Power & Energy Society General Meeting, 1–5. Chicago, IL: IEEE, 2017.	PV-Generator	Very Short Term, Short Term	Meteorologische Daten (Temperatur, Luftfeuchtigkeit, onneneinstrahlung)	combined model based on multivariate time series model
Malvoni, Maria, und Nikos Hatziargyriou. „One-Day Ahead PV Power Forecasts Using 3D Wavelet Decomposition“. In 2019 International Conference	PV-Anlagen an verschiedenen Standorten einer Insel	Short Term		KNN (SVM)

on Smart Energy Systems and Technologies (SEST), 1–6. Porto, Portugal: IEEE, 2019.				
Manjili, Yashar Sahraei, Rolando Vega, und Mo M. Jamshidi. „DataAnalytic-Based Adaptive Solar Energy Forecasting Framework“. IEEE Systems Journal 12, Nr. 1 (März 2018): 285–96.	PV-Anlage	Short Term	Temperatur, Luftdruck, Grad der Bewölkung, Sonneneinstrahlung	KNN (MLP)
Munir, Muhammad Asim, Abraiz Khattak, Kashif Imran, Abasin Ulasyar, und Adeel Khan. „Solar PV Generation Forecast Model Based on the Most Effective Weather Parameters“. In 2019 International Conference on Electrical, Communication, and Computer Engineering (ICECCE), 1–5. Swat, Pakistan: IEEE, 2019.	20,8-kW-PV-System	Short Term	Temperatur, Taupunkt, relative Luftfeuchtigkeit und Windgeschwindigkeit	KNN (MLP)
Senapati, Rajendra Narayan, Nirod Chandra Sahoo, und Sukumar Mishra. „Convolution Integral Based Multivariable Grey Prediction Model for Solar Energy Generation Forecasting“. In 2016 IEEE	Reihe von Solarpanel Daten einer Region	Mid Term	Sonneneinstrahlung, Temperatur	Convolution Integral based Multivariable Grey Model

International Conference on Power and Energy (PECon), 663–67. Melaka, Malaysia: IEEE, 2016.				
Snegirev, Denis A., Stanislav A. Eroshenko, Alexandra I. Khalyasmaa, Valeria V. Dubailova, und Alina I. Stepanova. „Day-Ahead Solar Power Plant Forecasting Accuracy Improvement on the Hourly Basis“. In 2019 IEEE Conference of Russian Young Researchers in Electrical and Electronic Engineering (EIConRus), 1088–91. Saint Petersburg and Moscow, Russia: IEEE, 2019.	Solkraftwerk	Short Term	Meteorologische Daten (Lufttemperatur, -feuchtigkeit, Windgeschwindigkeit, Grad der Bewölkung, Neigung der Sonneneinstrahlung, Transparenzfaktor)	Regressionsanalyse
Tian, Jun, Yong-qiang Zhu, und Jia-neng Tang. „Photovoltaic Array Power Forecasting Model Based on Energy Storage“. In 2010 5th International Conference on Critical Infrastructure (CRIS), 1–4. Beijing, China: IEEE, 2010.	PV generation system	Short term	Sonneneinstrahlungsintensität, Array-Effizienz, Installationswinkel, atmosphärischer Druck, Temperatur, etc.	Support-Vektor-Regressionsmodell (SVR)
Yao, Leather, und Teng-Shih Tsai. „Novel Hybrid Scheme of Solar Energy Forecasting for Home Energy Management System“. In 2016 IEEE International Conference on	HEMS (Home Energy Management System)	Short Term	Wettertypen (sonnig, regnerisch, bewölkt)	KNN (RNN)

Internet of Things (IThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData), 150–55. Chengdu, China: IEEE, 2016.				
---	--	--	--	--

Zusammenschluss von (erneuerbaren) Energien

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Andrade, Jose R., und Ricardo J. Bessa. „Improving Renewable Energy Forecasting With a Grid of Numerical Weather Predictions“. IEEE Transactions on Sustainable Energy 8, Nr. 4 (Oktober 2017): 1571–80.	PV- und Wind- Kraftwerk	Short Term	Windrichtung, - geschwindigkeit, Grad der Wolkenbedeckung, Temperatur	Gradient Boosting Trees
Charfi, Sana, Ahmad Atieh, Nabiha Brahmi, und Maher Chaabene. „Multi-Criteria Fuzzy Algorithm for Energy Management of a Stanalone Hybrid System“. In 2017 8th International Renewable Energy Congress (IREC), 1–6. Amman, Jordan: IEEE, 2017.	hybrid PV /batteries bank/diesel generator renewable solar energy system		Temperatur, Strahlung	Fuzzy-Logic, ARMA (im PV System)

<p>Makhloufi, Saida, Mohammed Debbache, und Saliha Boulahchiche. „Long-Term Forecasting of Intermittent Wind and Photovoltaic Resources by Using Adaptive Neuro Fuzzy Inference System (ANFIS)“. In 2018 International Conference on Wind Energy and Applications in Algeria (ICWEAA), 1–4. Algiers: IEEE, 2018.</p>	<p>Windpark, PV-Analgen</p>	<p>Short Term</p>	<p>Meteorologische Daten (Temperatur, Luftfeuchtigkeit, druck, Sonneneinstrahlung, Windgeschwindigkeit)</p>	<p>KNN (ANFIS)</p>
<p>Yuan, Baolei, Alian Chen, Chunshui Du, und Chenghui Zhang. „Hybrid AC/DC Microgrid Energy Management Based on Renewable Energy Sources Forecasting“. In 2017 36th Chinese Control Conference (CCC), 2870–75. Dalian, China: IEEE, 2017.</p>	<p>Hybrid AC/DC Microgrid Energy Management System</p>	<p>Short Term</p>		<p>KNN (MPSO-BP)</p>
<p>Zhongping, Yan, Lei Weimin, Gao Feng, Wu Tao, Zhang Gaili, Wang Bin, Rui Xiaoguang, und Wang Haifeng. „Integrated Wind and Solar Power Forecasting in China“. In Proceedings of 2013 IEEE International Conference on Service Operations and Logistics, and Informatics, 500–505. Dongguan, China: IEEE, 2013.</p>	<p>Zwei Windparks, ein PV-Park</p>	<p>Very Short Term, Short Term</p>	<p>Meteorologische Daten (Grad der Bewölkung)</p>	

Neuartige Energieerzeuger

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Jeon, Jooyoung, und James W. Taylor. „Short-Term Density Forecasting of Wave Energy Using ARMA-GARCH Models and Kernel Density Estimation“. International Journal of Forecasting 32, Nr. 3.	Pelamis P2-Gerät	Short Term	Wellenhöhe, -periode, -energiefluss, Windgeschwindigkeit	Regressionsbasierte Methode, conditional kernel density estimation, ARMAGARCH models

Erzeugung und Verbrauch

Quelle	Datenerzeuger	Fristigkeit	Exogene Faktoren	Methodik
Amjady, Nima, Farshid Keynia, und Hamidreza Zareipour. „Short-Term Load Forecast of Microgrids by a New Bilevel Prediction Strategy“. IEEE Transactions on Smart Grid 1, Nr. 3 (Dezember 2010): 286–94.	Stromsystem, eines Universitätscampus	Short Term	Meteorologische Daten (Temperatur, Luftfeuchtigkeit, etc.), Kalendereffekte	KNN (MLP)
Arkhangelski, Jura, Abdou-Tankari Mahamadou, und Gilles Lefebvre. „Data Forecasting for Optimized Urban Microgrid Energy Management“. In 2019 IEEE International Conference on Environment	u.a. Smart Meter	Short Term	Meteorologische Daten	KNN (LSTM)

and Electrical Engineering and 2019 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I&CPS Europe), 1–6. Genova, Italy: IEEE, 2019.				
Ayoub, Nasser, Farayi Musharavati, Shaligram Pokharel, und Hossam A. Gabbar. „ANN Model for Energy Demand and Supply Forecasting in a Hybrid Energy Supply System“. In 2018 IEEE International Conference on Smart Energy Grid Engineering (SEGE), 25–30. Oshawa, ON: IEEE, 2018.	Versorgungssystem eines Hotelgebäudes, lokale Behörde für Wettervorhersagedienst	Short Term	Meteorologische Daten, Kalendereffekte (Feiertage)	KNN (MLP)
Bracale, Antonio, Pierluigi Caramia, Guido Carpinelli, Anna Rita Di Fazio, und Pietro Varilone. „A Bayesian-Based Approach for a ShortTerm Steady-State Forecast of a Smart Grid“. IEEE Transactions on Smart Grid 4, Nr. 4 (Dezember 2013): 1760–71.	Windparks, Photovoltaik-Kraftwerken	Short Term	Windgeschwindigkeit, Wolkenbedeckung	probabilistic steady-state analysis
Byung Ha Lee, und Jin Ah Yang. „A Study on Optimal Operation of Microgrids Considering the Uncertainty of Renewable Generation and Load by Use of Duration Curves“. In 2015 IEEE Power & Energy Society General Meeting, 1–5. Denver, CO, USA: IEEE, 2015.	Virtuelles MicrogridSystem einer Insel	Short Term		Stochastic optimal operation/ MonteCarlo-Methode
Changsong, Chen, Duan Shanxu, und Yin Jinjun. „Research of Energy Management System of Distributed Generation Based on Power Forecasting“, o. J., 4.	distributed generation systems	Short Term	Meteorologische Daten, Kalendereffekte (day-type)	KNN (MLP)

Funabashi, T., Goro Fujita, Kaoru Koyanagi, und Ryuichi Yokoyama. „Field Tests of a Microgrid Control System“. In Proceedings of the 41st International Universities Power Engineering Conference, 232–36. Newcastle upon Tyne, UK: IEEE, 2006.	Verteiler/Energieversorgungssystem	Short Term	Meteorologische Daten, Kalendereffekte	KNN (MLP)
Ge, Yan, Kejun Qian, Jiachang Dai, und Chengke Zhou. „Modelling of Domestic Load Demand in the Presence of Microgrid with Wind and Photovoltaic Resources“. In 2015 International Conference on Smart Grid and Clean Energy Technologies (ICSGCE), 180–86. Offenburg, Germany: IEEE, 2015.	Beispielhaushalt, Wind- und Solar-Generatoren	Short Term	Windgeschwindigkeit, Temperatur, Sonneneinstrahlung, Kalendereffekte	Multiple Gaussian distribution, AR, ARMA
Husein, Munir, und Il-Yop Chung. „Impact of Solar Power and Load Demand Forecast Uncertainty on the Optimal Operation of Microgrid“. In 2019 IEEE PES/IAS PowerAfrica, 199–203. Abuja, Nigeria: IEEE, 2019.	Großes Bürogebäude mit PV und ESS (energy storage system)	Short Term	Kalendereffekte, Meteorologische Daten	KNN, k-means clustering algorithm
Iwafune, Yumiko, Yoshie Yagita, Takashi Ikegami, und Kazuhiko Ogimoto. „Short-Term Forecasting of Residential Building Load for Distributed Energy Management“. In 2014 IEEE International Energy Conference (ENERGYCON), 1197–1204. Cavtat, Croatia: IEEE, 2014.	HEMS (home energy management system)	Short Term	Kalendereffekt, Temperatur (Sonneneinstrahlung, Trockentemperatur, Taupunkttemperatur, rel. Luftfeuchtigkeit)	MLR
Izzatillaev, Jurabek, und Ziyodulla Yusupov. „Short-Term Load Forecasting in Grid-Connected Microgrid“. In 2019 7th International Istanbul Smart Grids and	Stromnetz einer Geschäftsbank	Short Term		KNN (MLP)

Cities Congress and Fair (ICSG), 71–75. Istanbul, Turkey: IEEE, 2019.				
Jaganmohan Reddy, Y, Y V Pavan Kumar, V Sunil Kumar, und K Padma Raju. „Distributed ANNs in a Layered Architecture for Energy Management and Maintenance Scheduling of Renewable Energy HPS Microgrids“. In 2012 International Conference on Advances in Power	Vier Microgrid-Systeme	Short Term, Mid Term	Kalendereffekte, Temperatur, Sonneneinstrahlung	KNN (Multi-layer feed forward neural
Conversion and Energy Technologies (APCET), 1–6. Mylavaram, Andhra Pradesh, India: IEEE, 2012.			und Dauer, Windgeschwindigkeit	networks (MLFFNN))
Jain, Prateek, Jacob A. Mueller, Jonghyun Park, Robert Landers, und Jonathan W. Kimball. „Battery Optimization in Microgrids Using Markov Decision Process Integrated with Load and Solar Forecasting“. In 2018 9th IEEE International Symposium on Power Electronics for Distributed Generation Systems (PEDG), 1–8. Charlotte, NC, USA: IEEE, 2018.	20 Häuser, von denen 10 mit PV-Paneeelen ausgestattet sind	Short Term, Mid Term	Kalendereffekte, Temperatur, relative Luftfeuchtigkeit, Grad der Bewölkung	ARIMA
Lee, Wonjun, Jaesung Jung, und Munsu Lee. „Development of 24-hour Optimal Scheduling Algorithm for Energy Storage System Using Load Forecasting and Renewable Energy Forecasting“, o. J., 5.	Energy Storage System (ESS)	Very Short Term, Short Term	Kalendereffekte, Meteorologische Daten (Temperatur, Bewölkungsgrad,	Mean Absolute Percentage Error (MAPE)

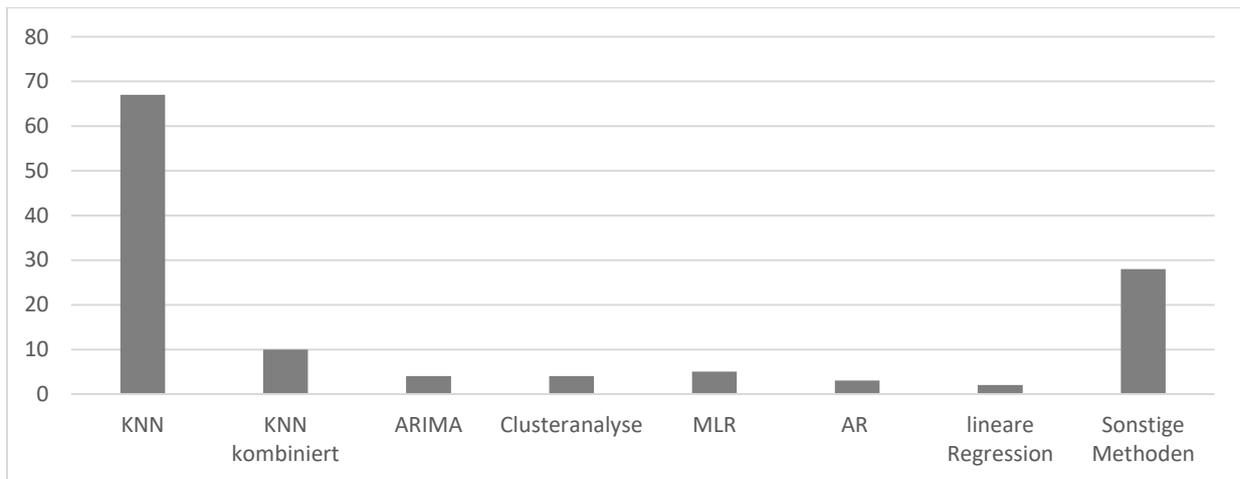
			Niederschlag, Windrichtung und geschwindigkeit, Luftfeuchtigkeit)	
Llanos, J., D. Saez, R. Palma-Behnke, A. Nunez, und G. Jimenez-Estevez. „Load Profile Generator and Load Forecasting for a Renewable Based Microgrid Using Self Organizing Maps and Neural Networks“. In The 2012 International Joint Conference on Neural Networks (IJCNN), 1–8. Brisbane, Australia: IEEE, 2012.	Online-Messungen		Short Term	Verbraucherinformationen KNN (SOM)
Ma, Xiandong. „State-of-the-Art Forecasting Algorithms for Microgrids“, o. J., 6.	Universitätscampus mit Windkraftanlage		Short Term	Meteorologische Daten (Wind-geschwindigkeit), Kalendereffekte, Verbrauchsverhalten Radial Basis Function with K-Means algorithm
Meer, Dennis van der, Gautham Ram Chandra Mouli, German MoralesEspana Mouli, Laura Ramirez Elizondo, und Pavol Bauer. „Energy Management System With PV Power Forecast to Optimally Charge EVs at the Workplace“. IEEE Transactions on Industrial Informatics 14, Nr. 1 (Januar 2018): 311–20.	Energymanagementsystem		Short Term	Kalendereffekte ARIMA
Michaelson, Dennis, Hisham Mahmood, und Jin Jiang. „A Predictive Energy Management System Using Pre-Emptive Load Shedding for Islanded Photovoltaic Microgrids“. IEEE Transactions on Industrial Electronics 64, Nr. 7 (Juli 2017): 5440–48.	Energiemanagementsystem (EMS) für ein inselgebundenes Mikronetz mit photovoltaischer Erzeugung und Batteriespeicherung		Short Term	Meteorologische Daten state-of-charge Vorhersage

Saez, Doris, Fernand Avila, Daniel Olivares, Claudio Canizares, und Luis Marin. „Fuzzy Prediction Interval Models for Forecasting Renewable Resources and Loads in Microgrids“. IEEE Transactions on Smart Grid 6, Nr. 2 (März 2015): 548–56. https://doi.org/10.1109/TSG.2014.2377178 .	Universitätscampus	Short Term	Meteorologische Daten (Windgeschwindigkeit, richtung, Sonneneinstrahlung, Temperatur)	Fuzzy Mode-ling
Sauter, Patrick S., Philipp Karg, Mathias Kluwe, und Soren Hohmann. „Load Forecasting in Distribution Grids with High Renewable Energy Penetration for Predictive Energy Management Systems“. In 2018 IEEE PES Innovative Smart Grid Technologies Conference Europe (ISGT-Europe), 1–6. Sarajevo: IEEE, 2018.	Zwei Umspannwerke, Deutschland	Very Short Term, Short Term	Kalendereffekte, Temperatur, Bewölkungsgrad, Windgeschwindigkeit und - richtung	KNN (MLP)
Sone, Akihito, Takeyoshi Kato, Toyonari Shimakage, und Yasuo Suzuoki. „Influence of Forecast Accuracy of Photovoltaic Power Output on Capacity Optimization of Microgrid Composition under 30-Minute Power Balancing Control“. Electrical Engineering in Japan 182, Nr. 2 (30. Januar 2013): 20–29.	distributed generator/photovoltaic power generation system	Short Term	Meteorologische Daten (Grad der Bewölkung, Temperatur)	
Tan, Mao, Ji-Cheng Jin, und Yong-Xin Su. „An Ensemble Learning Approach for Short-Term Load Forecasting of Grid-Connected Multi-Energy Microgrid“. In 2019 IEEE Symposium Series on Computational Intelligence (SSCI), 497–502. Xiamen, China: IEEE, 2019.	Gateway-Knotens eines netzgekoppeltes Microgrids	Short Term	Temperatur, Sonneneinstrahlung	KNN (gradient boosted regression trees)

Von denjenigen Fachartikeln, die sich mit Prognosen im Microgrid beschäftigen, konzentrieren sich knapp die Hälfte, 49%, auf den Verbrauch, 33% beschäftigen sich mit der Erzeugung und die übrigen 18% betrachten sowohl die Erzeugung als auch den Verbrauch.

Mit Blick auf die eingesetzte Methodik werden insbesondere künstliche neuronale Netze eingesetzt, wobei in 67 Studien ein solches Netz konstruiert und trainiert wurde. Weitere Methoden für Prognosen im Microgrid sind hybride Methoden, ARIMA, Clusteranalyse, multiple lineare Regression (MLR), Autoregression (AR) sowie eine Reihe weiterer einzelner Vorgehensweisen. Abbildung 3 verdeutlicht die Häufigkeit des jeweiligen Einsatzes.

Abbildung 2: Übersicht der unterschiedlichen Prognosemethoden



Quelle: Eigene Darstellung.

Hinsichtlich der Fristigkeit unterscheiden sich die Studien deutlich: So konzentrieren sich 104 Studien auf den Zeitraum „short term“, nur 16 Studien auf „very short term“ und 3 Studien auf „mid term“. Eine „long term“ Untersuchung wird in keiner der Studien vorgelegt.

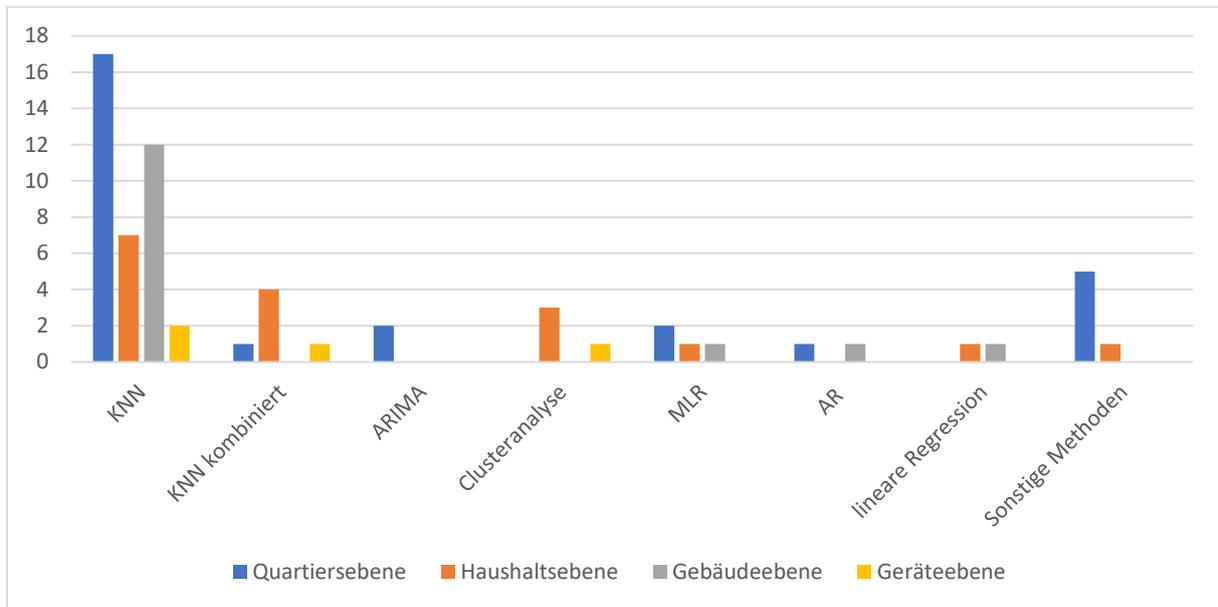
Hinsichtlich der exogenen Einflussgrößen, den sogenannten Features, werden am häufigsten meteorologische Daten genutzt, gefolgt von Kalendereffekten. Deutlich seltener zum Einsatz kommen Verbraucherinformationen und die Innentemperatur von Gebäuden. Nur vereinzelt werden das finanzielle Wachstum und Komforteinflussfaktoren verwendet.

3.1 Betrachtungsebene Stromverbrauch

Studien, die sich Stromverbrauchsprognosen im Microgrid annehmen, legen den Fokus zu 34% auf die Quartiersebene. Zu gleichen Anteilen, jeweils 26%, werden Prognosemodelle für Haushalte und Gebäude(komplexe) erarbeitet. Lediglich 8% der Studien widmen sich Orts- und Städtetnetzen und 6% der Studien stellen ihre Prognosemodelle auf Geräteebene ab.

Nachfolgende Abbildung 4 illustriert die Häufigkeit der eingesetzten Prognosemodelle auf den einzelnen Netzebenen des Microgrids.

Abbildung 3: Verwendete Methodiken innerhalb der Verbrauchsebene

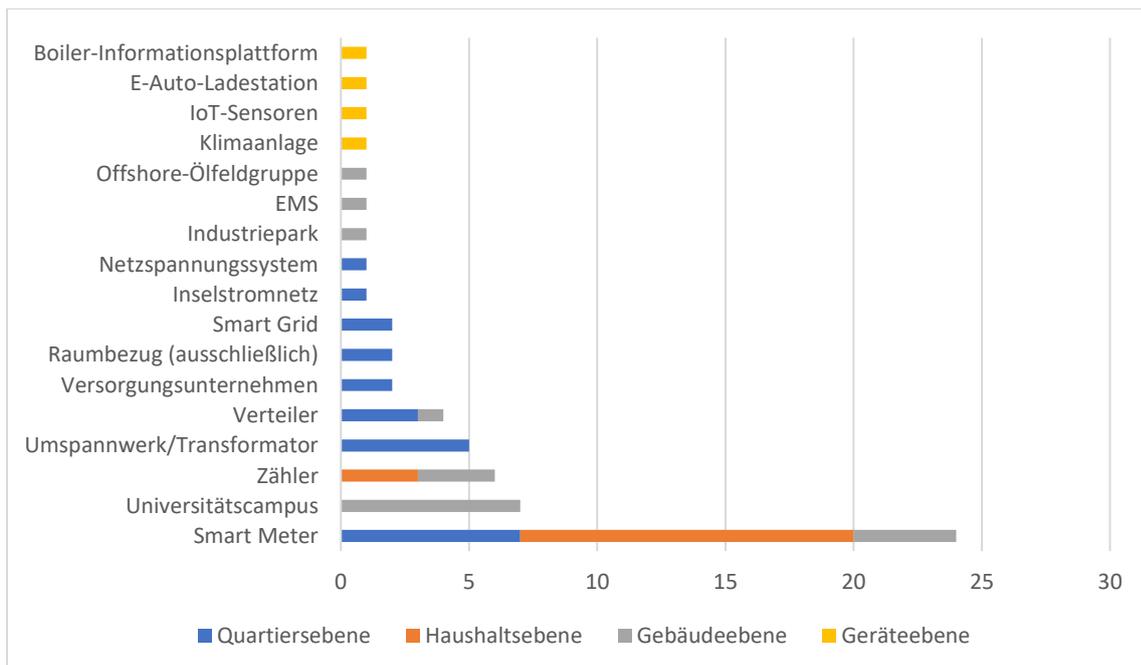


Quelle: Eigene Darstellung.

Für die Quartiere werden insbesondere meteorologische Daten, Kalendereffekte, Verbraucherinformationen und finanzielles Wachstum als exogene Faktoren bei der Prognose herangezogen. Auf Gebäude- und Geräteebene wird zudem die Innentemperatur als Feature aufgenommen. In lediglich einer Studie werden zusätzlich Komforteinflussfaktoren berücksichtigt.

Nachfolgende Abbildung 5 veranschaulicht die zum Einsatz kommenden Datenerzeuger, bei denen das Smart Meter eine prädominante Rolle einnimmt.

Abbildung 4: Datenerzeuger für Prognosemodelle der Verbrauchsebene



Quelle: Eigene Darstellung.

3.1.1 Orts- und Städtetze und Quartiere

Auf der Ebene der Orts- und Städtetze findet sich in fünf Fachartikeln die ausschließliche Verwendung von KNNs oder hybriden Methoden. Maßgebliche Features sind meteorologische Daten und Kalendereffekte. Als Datenerzeuger dienen Umspannwerke und Transformatoren. Der Prognosehorizont ist in allen Fällen „short term“.

Von den 22 Artikeln, die sich mit Prognosen auf Quartiersebene beschäftigen, enthalten 13 die Entwicklung eines KNN, häufig als hybrides Modell in Kombination mit anderen Verfahren, wie zum Beispiel ARIMA oder Support Vector Machine (SVM). In zwei Studien wurde ARIMA als Prognose-Methode genutzt. Die übrigen sieben Artikel enthalten verschiedene Regressions- und Autoregressionsansätze, ein exponentielles Glättungsmodell, ein Chaos Prediction Model, Selfadaptive Weighting Algorithm (SAW) sowie Standard Load Profiles (SLP).

Die Fristigkeit beträgt fast ausschließlich „short term“, mit Ausnahme von einer Studie, die sich einer „mid term“ Prognose annimmt. In acht Studien werden Smart Grid und Smart Meter als Datenerzeuger verwendet. Daneben werden lokale Verteiler oder anderweitig verfügbare Lastdaten genutzt. In sechs Studien sind keine dezidierten Angaben darüber zu finden, welche exogenen Faktoren tatsächlich verwendet werden. In allen anderen werden hauptsächlich meteorologische Daten und Kalendereffekte in die Prognosen einbezogen.

3.1.2 Haushalte

Von den 17 Fachartikeln, die sich mit Prognosen auf Haushaltsebene beschäftigen, konzentrieren sich zehn auf KNNs. Davon setzen lediglich zwei Studien die für Zeitreihenanalysen prädestinierten LSTM ein. Die restlichen Studien verwenden hybride Ansätze unter Einbezug von Clusteranalysen, Support Vector Regression (SVR), ARIMA und einem Wavelet Neural Network (WNN). Neben den KNNs finden sich auf dieser Ebene ebenfalls lineare Regressionsmodelle, reine Clusteranalysen, Kalman Filter und Conditional Kernel Density (CKD) wieder.

Als Fristigkeit wird in allen Studien „short term“ angesetzt. In 12 der 17 Studien sind Smart Meter die Datenerzeuger, in den übrigen Studien werden die Daten durch Stichproben erhoben. Bei den exogenen Faktoren dominieren wiederum meteorologische Daten und Kalendereffekte. Lediglich zwei Studien beziehen zusätzlich das Verbrauchsverhalten mit ein.

3.1.3 Gebäude(komplex)

Auf der Gebäude(komplex)-Ebene nutzen 11 der 17 Studien KNNs. Reine LSTM-Netze werden nicht eingesetzt, stattdessen wird auf hybride Modellvarianten mit Gradient Boosting Decision Tree zurückgegriffen. Neben KNNs kommen Korrelations- und Regressionsanalysen sowie ARIMA in Verbindung mit einer Clusteranalyse bzw. einer MLR zum Einsatz.

Die Fristigkeit ist auch in dieser Ebene überwiegend „short term“. Eine Studie ergänzt den Prognosehorizont um „mid term“, eine weitere um „very short term“ und „mid term“. Die genutzten

Datenerzeuger sind auf dieser Ebene deutlich vielfältiger. Nur vier der Studien nutzen Smart Meter, die restlichen bedienen sich verfügbarer Lastdaten, Daten eines Industrieparks und eines Universitätscampus sowie analoger Zähler von Wohn- und Geschäftsgebäuden. Neben den bereits bekannten meteorologischen Daten und Kalendereffekten greifen drei Studien ausschließlich auf Innentemperaturdaten als exogene Faktoren zurück.

3.1.4 Gerät

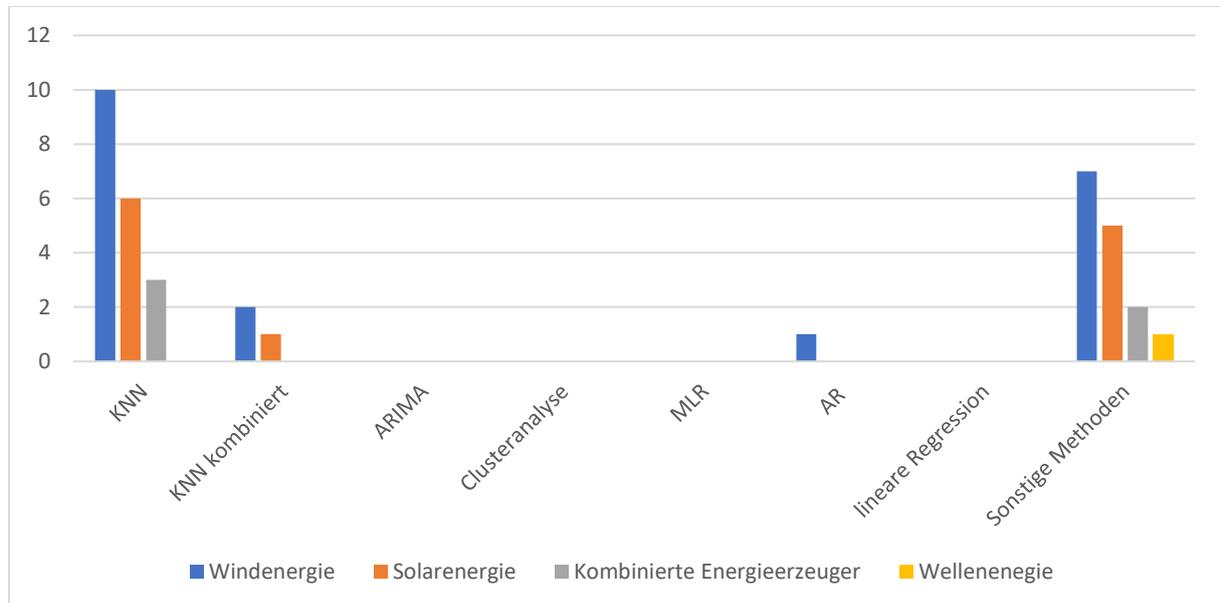
Von den vier Studien auf Geräteebene nutzen drei ein KNN. Dabei handelt es sich in einer Studie um ein WNN, in einer weiteren um ein CNN-LSTM und schließlich noch um ein autoregressives KNN. Nur ein Artikel stellt die Prognose auf eine Clusteranalyse ab. Die Fristigkeit beträgt in allen Fällen „short term“. Als Datenerzeuger dienen Daten von Klimaanlage, IoT-Sensoren, Elektrofahrzeug-Ladestationen sowie Daten einer Management Plattform. Lediglich die WNN-Studie berücksichtigt meteorologische Daten und Kalendereffekte als exogene Faktoren, während die restlichen Studien auf die Temperatur, Luftfeuchtigkeit und die Auslastung eines Gerätes als exogene Variablen zurückgreifen.

3.2 Betrachtungsebene Stromerzeugung

Die knappe Mehrheit der Studien im Bereich der Stromerzeugung von 51% fokussiert sich auf die Windenergie. 34% der Studien entwickeln Prognosemodelle für Solarenergie und 12% kombinieren mehrere Energieerzeuger miteinander. In nur einer Studie wird ein Prognosemodell für Wellenenergie entwickelt.

Hinsichtlich der verwendeten Methodiken kommen häufig KNNs oder hybride Varianten zum Einsatz. Daneben gibt es außerdem eine Reihe spezifischer Methoden. Klassische Verfahren werden im Bereich der Erzeugung nicht eingesetzt und lediglich eine Studie nutzt die Autoregression. Stromerzeugung mittels erneuerbarer Energien ist nicht von Kalender- und Zeiteffekten abhängig, weshalb sich keine wiederholenden Muster einstellen, die mittels ARIMA detektiert werden können.

Abbildung 5: Verwendete Methodiken innerhalb der Erzeugungsebene



Quelle: Eigene Darstellung.

In Bezug auf die Fristigkeit nutzt die Mehrheit der Studien „short term“ - 23 von 41 Studien und ein beträchtlicher Anteil konzentriert sich auf „very short term“ - 13 von 41 Studien. Lediglich eine Studie verfolgt den Prognosehorizont „mid term“. Die exogenen Faktoren sind fast ausschließlich meteorologische Daten, nur eine Studie nutzt Kalendereffekte.

3.2.1 Windenergie

Insgesamt wurden 21 Fachartikel im Bereich der Windenergie identifiziert. Von den 12 Studien, die KNNs entwickeln, nutzen sechs Studien MLPs, alle weiteren nutzen hybride Varianten und eine Vielzahl verschiedener KNN-Derivate. Die verbleibenden 9 Studien zeigen ebenfalls eine Vielfalt klassischer und spezifischer Methoden, wie: Adaptive Estimation Methods (kovarianzbasierte Methode), Analogue Ensemble Kalman Filter, Quantile Regression, Autoregression, Hilbert-Huang-Transformation, ARCH/ARMAX, k-nearest neighbors, Kernel Density, Multi-to-multi Mapping SDAE, Nonparametric Regression und Regression Tree.

Die Fristigkeit liegt bei 11 Studien bei „short term“ und bei acht Studien bei „very short term“. Die Daten werden mehrheitlich direkt durch Windparks, Windenergieanlagen oder Windturbinen generiert. Bei den meteorologischen Daten, welche als Features genutzt werden, spielen vor allem die Windgeschwindigkeit, die Windrichtung und teilweise die Temperatur eine Rolle.

3.2.2 Solarenergie / Photovoltaik

Von den 14 Fachartikeln, welche Prognosemodelle für Stromerzeugung durch Solaranlagen entwickeln, nutzen die Hälfte KNNs und hybride Varianten. Ein neuer Netz-Typ ist hier das Physical Hybrid

Artificial Neural Network (PHANN), welches auf einem KNN und grundlegenden physikalischen Nebenbedingungen der Solaranlage basiert. Des Weiteren kommen eine Support Vector Regression, k-nearest Neighbour und Fuzzy Logic zum Einsatz.

Neun Studien konzentrieren sich auf eine „short term“ Fristigkeit, vier Studien auf „very short term“ und eine auf „mid term“. Die Daten werden durch Solaranlagen, einzelne Solarkraftwerke, Solarpanels, Solarparks oder Energie Management Systeme bereitgestellt. Die exogenen Faktoren sind im Bereich der Solarenergie vielfältiger aufgestellt als im Bereich der Windenergie. Genutzt werden u.a. der Grad der Bewölkung, die Windrichtung und -geschwindigkeit, Temperatur, Sonneneinstrahlung, Luftfeuchtigkeit, der Wassergehalt der Wolken, der Installationswinkel oder der Taupunkt.

3.2.3 Kombinierte Energieerzeuger

Es gibt fünf Fachartikel, die die Stromerzeugung verschiedener Energieanlagen kombiniert prognostizieren. Darunter finden sich überwiegend KNNs und hybride Varianten.

Die Fristigkeit beträgt in drei der Studien „short term“, in einer Studie zusätzlich „very short term“ und in einer Studie fehlt diese Information. Die Daten werden direkt von Wind- und Solaranlagen generiert, in einem Fall wird ein hybrides Microgrid Energy Management System genutzt. Als exogene Faktoren werden u.a. die Temperatur, die Strahlung, Windrichtung und -geschwindigkeit, Grad der Bewölkung oder Luftfeuchtigkeit genutzt.

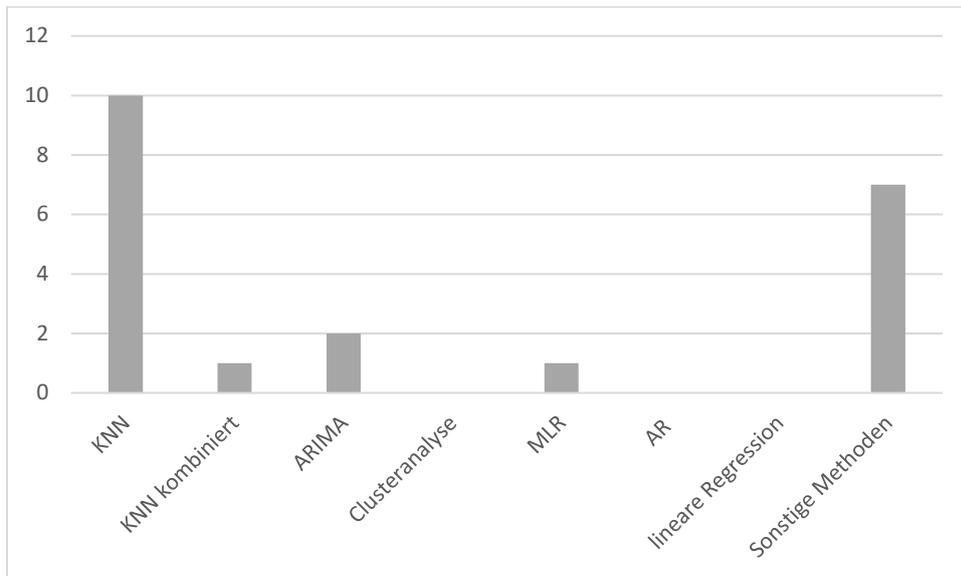
3.2.4 Wellenenergie

In einer Studie wird ein Prognose-Modell für Wellenenergie konstruiert. Hierfür wird eine regressionsbasierte Methode genutzt, „conditional kernel density estimation“ und ein ARMA-GARCH Model. Die Fristigkeit ist „short term“ und als Datenerzeuger dient ein Pelamis P2-Gerät. Exogene Faktoren sind die Wellenhöhe und -periode, der Energiefluss und die Windgeschwindigkeit.

3.3 Betrachtungsebene Erzeugung und Verbrauch

Auch bei den 22 Fachartikeln, die sich mit Prognosemodellen für die Erzeugung und den Verbrauch beschäftigen, dominieren die KNN in 10 Studien. Daneben findet man hybride Ansätze und klassische Methoden vor. Clusteranalysen, Autoregressionen oder lineare Regressionen werden in diesem Bereich nicht eingesetzt.

Abbildung 6: Verwendete Methodiken innerhalb der Ebene Erzeugung und Verbrauch



Quelle: Eigene Darstellung.

Erneut sind die MLPs unter den KNNs am häufigsten vertreten. Die anderen Studien setzen auf hybride Varianten. Sonstige Methoden sind Fuzzy Modeling, Multiple Gaussian Distribution in Verbindung mit ARMA oder die Monte-Carlo Simulation.

20 Artikel nutzen „short term“, zwei konzentrieren sich auf „very short term“. Die Datenerzeuger sind in dieser Kategorie vielfältig: 20 Häuser von denen 10 mit PV-Paneelen ausgestattet sind, Wind- und Solar-Generatoren, Systeme der verteilten Erzeugung, Energie Management Systeme, Online Messungen, Universitätscampus, Versorgungssystem eines Hotelgebäudes, Virtuelle Microgrid-Systeme einer Insel, Windpark und Solaranlagen und Umspannwerke.

Als exogene Faktoren kommen neben Kalendereffekten und meteorologischen Daten wie Temperatur, Sonneneinstrahlung, Niederschlag oder Bewölkungsgrad auch Verbraucherinformationen zum Einsatz. Zwei Studien beziehen das Verhalten der Verbraucher in ihre Prognosemodelle mit ein.

4 Daten

4.1 Inputgrößen (X)

Inputgrößen, auch als Features bezeichnet, sind die potenziellen Einflussfaktoren auf das Ergebnis. Die verwendeten Inputgrößen sind übersichtlich in nachfolgender Tabelle zusammengefasst.

Gebiets Aktivität	Beobachtungszeitraum
Gewerbe mit PV-Einspeisung	01.01.2018 – 01.01.2022
Freistehende Doppelhäuser	01.01.2018 – 01.01.2022
Mehrfamilienhäuser mit Kleingewerbe	01.01.2018 – 01.02.2021
Gemischtes Wohngebiet	01.01.2018 – 01.02.2022
Gewerbe	01.01.2018 – 01.01.2022
Summe aller Messungen	01.01.2018 – 01.01.2022
Kraftwerk	15.07.2017 – 28.05.2019
4 Stationen Wohngebiet, 2 Industrie	01.01.2021 – 31.12.2022

Tabelle 1: Rohdateninformationen von jedem Kraftwerk

4.1.1 Kontextuelle Merkmale

Wetter- und Kalenderdaten sind entscheidende Merkmale, die die Leistung der Lastprognose erheblich steigern können.

Die Nutzung von energieintensiven Geräten wie Klimaanlage und Heizungen ist eng mit den Wetterbedingungen wie Temperatur, Luftfeuchtigkeit, Windgeschwindigkeit, Sonneneinstrahlung und Bewölkungsgrad verbunden. Daher werden in vielen Studien aus Wetterdaten abgeleitete Eingangsvariablen häufig für kurzfristige Lastprognosen verwendet. Die Easy Global Weather API wird verwendet, um historische Wetterdaten und Wettervorhersagen zu erfassen. Das historische Wetter wird den Daten für das Training und die Tests hinzugefügt. Die Wetter-API bietet unterstündliche, stündliche und tägliche Daten zu den verschiedenen Wetterkomponenten. In diesem Projekt werden Informationen über Temperatur und Luftfeuchtigkeit verwendet. Die API liefert hingegen keine Prognosewerte für die Sonnenscheindauer. Deshalb sind diese manuell anhand der Sonnenaufgangs- und Sonnenuntergangsdaten zu berechnen.

Der Kalendereffekt ist ein essenzieller Faktor für die Stromnachfrage. Dieser beeinflusst die Lastprognose um 55 %. Den Daten werden die gängigen Feiertage Neujahr, Karfreitag, Ostermontag, Christi Himmelfahrt, 1. Mai, Pfingstmontag, Tag der Deutschen Einheit, Erster Weihnachtstag und Zweiter Weihnachtstag hinzugefügt.

Tagesinformationen: Diese Information beeinflusst die Lastprognose um 53 % (vor/nach einem Feiertag, (Nicht-)Arbeitstag, Wochentag usw.). Die Tagesinformationen werden über ein bestehendes Skript eingefügt.

4.1.2 Autokorrelierte Merkmale

Die aktuelle Last ist eng mit der historischen Last verbunden, da ein bestimmtes Muster regelmäßig auftritt. In dieser Studie wird die abhängige Größe Last (Y) der Vorwoche in viertelstündlicher Frequenz als Merkmal (X_{t-h}) verwendet. Zur Beschreibung der Last in Y_t wird das historische Zeitfenster $t - 15min, t - 30min, t - 45min, \dots, t - 2970 min, t - 2985 min, t - 3000 min$ betrachtet.

Inputgrößen		
Name	Einheit	Kurzbeschreibung
Temperatur	[°C]	Umgebungstemperatur
Luftfeuchtigkeit	[%]	
Sonnenscheindauer	[min/h]	
Jahreszeit		
Wochentag	Tag	
Stunde	h	
Monat	Monat	
Grid		Netzwerktyp

Tabelle 2: Zusätzlich aufgenommene Inputgrößen.

Der Grid-Type bezieht sich auf die Klassifizierung verschiedener dezentraler Strukturen auf der Grundlage ihrer Infrastruktur, Demografie und regionalen Merkmale und kann am ehesten mit *Netzwerktyp* übersetzt werden. Die Einbeziehung des Grids als Merkmal in das Last-Energie-Prognosemodell ermöglicht dem Modell, die einzigartigen Verhaltensweisen und Verbrauchsmuster zu erfassen, die mit jedem Grid-Type verbunden sind. Außerdem kann das Modell seine Vorhersagen auf der Grundlage der Merkmale der dezentralen Struktur anpassen, was zu genaueren Prognosen führt. Durch die Einbeziehung dieses Features soll untersucht werden, ob es wertvolle Erkenntnisse liefert und zur Verbesserung der Vorhersagegenauigkeit beiträgt.

In dieser Studie werden mehrere Hauptarten von Grids in Betracht gezogen, die auf den Aktivitäten in den jeweiligen Gebieten basieren:

1. **Gewerblich mit PV-Einspeisung:** Dieses Grid umfasst Gebiete mit gewerblichen Einrichtungen, die mit solarphotovoltaischen (PV) Systemen zur Stromerzeugung ausgestattet sind.
2. **Freistehende und Doppelhäuser:** Dieses Grid umfasst hauptsächlich Wohngebiete mit freistehenden oder Doppelhäusern.

3. **Kleine Geschäftswohngebäude:** Dieses Grid umfasst Gebiete mit kleinen Unternehmen und Mehrfamilienhäusern.
4. **Gemischte Wohngebiete:** Dieses Grid repräsentiert Gebiete mit einer Kombination von Wohnimmobilien, einschließlich Einfamilienhäusern, Wohnungen und Reihenhäusern.
5. **Gewerbliche Kunden:** Dieses Grid konzentriert sich auf Gebiete mit einer hohen Konzentration von gewerblichen Kunden wie Büros, Einkaufszentren, Restaurants und anderen Unternehmen.
6. **Gemischte Kunden:** *Gemischte Kunden* umfasst Gebiete mit einer Mischung aus Wohn- und Geschäftskunden und spiegelt ein dynamisches Zusammenspiel von Verbrauchsmustern wider.
7. **Andere:** Diese Kategorie umfasst Gebiete, die sich nicht genau in die zuvor genannten Grid-Typen einordnen lassen, aber dennoch einzigartige Merkmale aufweisen, die den Energieverbrauch beeinflussen können.

Das Merkmal Grid-Type wird als kategoriale Variable in den vereinheitlichten Datensatz integriert. Jeder Datenpunkt erhielt ein Grid-Type-Label basierend auf der entsprechenden dezentralen Struktur und ihrer Hauptaktivität. Das Grid-Merkmal wird anschließend als *One-Hot-Encoding* kodiert, um die verschiedenen Kategorien als binäre Variablen darzustellen. Dies ermöglicht dem Modell, die Auswirkungen jedes Grid-Type unabhängig voneinander zu berücksichtigen.

Bei der kurzfristigen Lastprognose werden die in bestimmten Zeitspannen $t + 1, \dots, t + n$ benötigten Stromerzeugungsleistungen (Y) mit Hilfe von mehrstufigen multivariaten Zeitreihen vorhergesagt. Als Zeithorizont dienen 15 Minuten bis zu einer Woche, wobei unabhängige Variablen wie Kalendereffekte (X_1) und Wetterdaten (X_2) herangezogen werden.

4.2 Outputgröße(n) (Y)

Als Outputgröße, auch als endogene oder abhängige Größe bezeichnet, dient die Energielast, also die Leistung, die einem Stromnetz entnommen wird¹⁵. Ziel dieser Forschung ist es, das am besten für Energielastprognosen geeignete KI-System ausfindig zu machen, indem eine möglichst akkurate Steuerung von Stromproduktion und -verbrauchsmengen mit den verschiedenen, weiter unten aufgeführten, Systemen erprobt wird. Als Qualitätsmetriken für die KI-Systeme dienen MAE und MAPE¹⁶. Die KI-Systeme, die die geringsten Fehler aufweisen, lassen geeignete Stromsparprognosen zu und zeigen zudem Einsparpotenziale auf.

¹⁵ Der Begriff Last wird in vielfältigen Bedeutungen verwendet. In der Elektro- und Energietechnik steht der Begriff Last für die Entnahme von Energie. Strom einer gewissen Stärke wird einem Stromnetz durch angeschlossene Verbraucher entnommen. Hiermit ist auch eine gewisse elektrische Leistung verbunden, d.h. eine bezogene Energiemenge pro Zeiteinheit. Die Leistung P [Watt] entspricht dem Produkt aus Stromstärke I [Ampere] und Spannung U [Volt].

¹⁶ Die Werte umfassen den mittleren absoluten Fehler (MAE) und den mittleren absoluten prozentualen Fehler (MAPE).

4.3 Preprocessing

Bevor die Daten mittels Trainierens (eigentliche Verarbeitung der Daten) für eine modellhafte Beschreibung eines Sachverhalts durch ein KNN verwendet werden, sollten die Daten vorverarbeitet werden. Die Vorverarbeitung, das Preprocessing der Daten, dient dazu, einige Probleme im Datenbestand zu beseitigen sowie die Daten für das Trainieren aufzubereiten. Nachfolgend sind einige Preprocessing-Schritte aufgeführt.

4.3.1 Fehlende Werte

Weisen die Input- und Outputgrößen fehlende Werte [engl. missing values] auf, so gibt es grundsätzlich zwei Möglichkeiten der Behandlung:

- Entfernen der Datensätze mit fehlenden Werten
- Ersetzen der fehlenden Werte durch statistische Lageparameter wie z.B. den Median oder den Durchschnittswert von X oder Y

Die Bewältigung von fehlenden Datenwerten stellt einen entscheidenden Schritt in der Analyse realer Datensätze dar. In diesem Forschungsvorhaben werden Lücken in den Datensätzen zur Energielast, zum Kalender und zu den Wetterdaten identifiziert. Zur Lösung dieses Problems wird ein zweistufiger Ansatz verfolgt.

Zu Beginn erfolgt eine gründliche Identifikation der fehlenden Datenwerte im Datensatz. Dabei werden alle Merkmale und Zeitstempel sorgfältig geprüft, um ein umfassendes Verständnis der vorhandenen Lücken zu gewinnen. Für die Energielastdaten werden Kalman-Filter-Techniken angewendet, ein mathematisches Verfahren zur Schätzung fehlender Werte, das gleichzeitig die sequenzielle Struktur der Daten berücksichtigt.

Hinsichtlich der Kalender- und Wetterdaten werden die fehlenden Werte, aufgrund der stündlichen Verfügbarkeit von Wetterdaten, durch die Berechnung des Mittelwerts zwischen zwei verfügbaren Zuständen ersetzt. Dieser Ansatz ermöglichte eine präzisere Annäherung an die fehlenden Werte.

4.3.2 Ausreißer

Ein zweiter Problembereich, der die Datenqualität betrifft, sind Ausreißer [engl. outlier].

Ausreißer können erhebliche Auswirkungen auf die Leistung und Genauigkeit des Lastprognosemodells haben. Zur Identifikation und Behandlung von Ausreißern wird eine gründliche Analyse des Datensatzes durchgeführt. Dabei werden statistische Verfahren wie Boxplots, Z-Scores oder der Interquartilsbereich (IQR) verwendet, um potenzielle Ausreißer zu identifizieren. Ausreißer werden als Datenpunkte definiert, die außerhalb eines zuvor festgelegten Schwellenwerts liegen, was auf eine signifikante Abweichung von der Normalverteilung hinweist. Für die Behandlung von Ausreißern gibt es mehrere Verfahren.

Im einfachsten Fall werden Ausreißern einfach in der Datenmenge belassen. Sofern sie reale Werte und keine Messfehler darstellen und man mit ihnen auch arbeiten möchte, spricht nichts dagegen, sie in der Datenmenge zu belassen. Ausreißer können aus der Datenmenge gelöscht werden. Ob dieses Verfahren in Erwägung gezogen werden soll, muss genau überprüft werden. Mit dem Entfernen von Datensätzen mit Ausreißern können nämlich auch weitere, ggf. wertvolle Informationen verloren gehen. Ausreißer lassen sich durch NA [engl. not available] ersetzen, womit sie zu fehlenden Werten gemacht werden. Anschließend können die Möglichkeiten im Umgang mit fehlenden Werten genutzt werden. Ein weiteres Verfahren ist das Winsorisieren. Beim Winsorisieren werden die Ausreißer auf bestimmte Quantilsgrenzen gesetzt. Dieses Verfahren kann aber muss nicht mit den Verfahren zur Definition von Ausreißern kombiniert werden. Entweder werden die, aus dem Verfahren nach Tukey oder aus der Maximum-Likelihood-Schätzung resultierenden, Ausreißer oder diejenigen Werte, die außerhalb vorgegebener Quantilsgrenzen liegen, auf die Quantilsgrenzen gesetzt. Wird beispielsweise das 5%-Quantil und das 95%-Quantil als Quantilsgrenzen vorgegeben, lassen sich alle Werte, die unterhalb des 5%-Quantils und alle Werte, die oberhalb des 95%-Quantils liegen, auf die entsprechenden Quantilsgrenzen setzen.

Die im Forschungsvorhaben ermittelten Ausreißer werden einer sorgfältigen Prüfung unterzogen und mithilfe des Kalman-Smoothing-Verfahrens korrigiert. Kalman-Smoothing ist eine statistische Technik, die dazu dient, Datenwerte in Zeitreihen zu glätten und zu verbessern. Dies geschieht durch die Berücksichtigung der sequenziellen Struktur der Daten und durch die Anwendung eines rekursiven Filterungsprozesses, um Ausreißer zu erkennen und durch geschätzte, glattere Werte zu ersetzen. Dadurch wird die Datenqualität erhöht und die Leistung von Prognosemodellen verbessert.

4.3.3 Zeitreihen

Eine Zeitreihe [engl. time series] ist eine chronologisch geordnete Folge von Merkmalswerten, bei der die betrachteten Merkmale x und y einen Zeit- oder Periodenindex t aufweisen: x_t und y_t . Die Werte von x und y werden über einen Zeitraum $t = 1 \dots T$ festgehalten, d.h. x_t und y_t bezeichnen die Werte von x und y zum Zeitpunkt t . t benennt die insgesamt Anzahl an Perioden innerhalb einer Zeitreihe. Bei Zeitreihen lassen sich *univariate* und *multivariate* Zeitreihen unterscheiden. Eine univariate Zeitreihe ist eine Zeitreihe, bei der lediglich eine Größe y_t vorliegt. Bei einer multivariaten Zeitreihe existieren neben y_t noch weitere erklärende Größen x_{1t} , x_{2t} usw. Daneben existiert mit einer parallelen Zeitreihe ein gelegentlich in der Literatur aufgeführter weiterer Typ, der jedoch hier nicht als eigenständiger Typ betrachtet und behandelt wird. Eine solche Zeitreihe zeichnet sich durch das gleichzeitige Vorhandensein mehrerer y und mehrerer x aus, die jeweils einen Verbund bilden und demnach nichts anderes darstellen als mehrere univariate oder multivariate Zeitreihen innerhalb einer einzigen Zeitreihe. Zeitreihen verlangen aufgrund des expliziten Zeitbezugs eine besondere Behandlung. Hierzu sind zwei Fragen zu beantworten:

1. Ist die Zeit selbst ein determinierender Faktor für die Werte von y ? Verändern sich die Werte von y ohne weiteres Zutun im Zeitablauf, so ist die Frage mit Ja zu beantworten. Eine positive Antwort erfordert die Herstellung von Stationarität durch Differenzierung.

2. Hängt der Wert von y zu einem Zeitpunkt t , y_t , von Werten von y zu früheren Zeitpunkten ab, y_{t-1} , y_{t-2} usw.? Wenn Ja, dann erfolgt die Bestimmung der optimalen Lag-Zahl mittels ARIMA(X).¹⁷

4.3.4 Differenziation / Stationarität

Im ersten Schritt wird Stationarität durch Differenzierung, d. h. der Bildung von Differenzen jeweils benachbarter Zeitreihenwerte, hergestellt.¹⁸ Stationarität benennt allgemein einen Zustand, bei dem sich äußere Gegebenheiten nicht ändern. In der Statistik wird der Begriff der Stationarität zur Beschreibung einer Situation gebraucht, bei der Verteilungsparameter wie der Mittelwert bzw. Erwartungswert und die Varianz zeitunabhängig sind. Nimmt beispielsweise der Mittelwert oder die Varianz einer Zeitreihe zu, so ist die Zeitreihe nicht stationär. Um dies nochmals zu wiederholen und zu verdeutlichen: Wenn die Zeit selbst die exogene, erklärende Größe für die Zeitreihenwerte einer endogenen Größe ist, so muss die Zeitreihe mittels Differenzierung stationarisiert werden.¹⁹ Die Herstellung einer stationären Zeitreihe ist wichtig, um spätere Prognosen nicht auf der Grundlage einer Scheinkorrelation vorzunehmen. Wenn die Zeitreihe nicht stationarisiert wird, besteht bei einer zeitbegründeten Zeitreihe die Gefahr einer Scheinkorrelation. Bei einer Scheinkorrelation [engl. spurious correlation] besteht ein tatsächlich beobachtbarer, jedoch unbegründbarer Zusammenhang. Ein gutes Beispiel hierfür ist der unter Umständen tatsächlich beobachtete Zusammenhang zwischen der Geburtenrate und der Storchpopulation. In der Literatur ist im Zusammenhang mit Scheinkorrelationen häufig von unbegründet die Rede. Nach Ansicht des Autors erscheint der Begriff *unbegründbar* geeigneter, da Korrelationen per se unbegründete Zusammenhänge darstellen, während Regressionen begründete Zusammenhänge sind. Bei einer Scheinkorrelation lässt sich eben keine Begründung für den Zusammenhang der untersuchten Größen finden. Für gewöhnlich werden auf der Grundlage von Korrelationen, im Sinne von unbegründeten Zusammenhängen, Regressionsmodelle im Sinne begründeter Zusammenhänge geformt. Besteht nun zwischen zwei Größen ein tatsächlicher, jedoch unbegründbarer Zusammenhang, so lässt sich daraus kein sinnvolles Regressionsmodell erzeugen.

Eine stationäre Zeitreihe ist eine Zeitreihe, deren Werte nicht von der Zeit abhängen.²⁰ Durch Differenzierung wird beispielsweise ein Trend aus der Zeitreihe eliminiert.²¹

¹⁷ Mehr dazu weiter unten in dem Kapitel 4

¹⁸ Vgl. Carlsberg, Predictive Analytics: Microsoft Excel. Indianapolis, Indiana: Que. (2013: 111).

¹⁹ Vgl. Hyndman/Athanasopoulos Forecasting: Principles and Practice. 2014. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp>. Carlsberg, Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que. (2013: 108 ff.).

²⁰ Vgl. Hyndman/Athanasopoulos Forecasting: Principles and Practice. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp>. (2014: 213).

²¹ Vgl. Carlsberg Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que. (2013: 136).

Die Bildung der **Differenzen** erfolgt gemäß

$$y_t^D = y_t - y_{t-1}, \forall t = 2 \dots T$$

Nachdem eine stationäre Zeitreihe vorliegt, wird diese auf Autokorrelation getestet.²² Im positiven Fall kommt es dann zum zweiten und anschließend zum dritten Schritt.

Im *zweiten Schritt* werden Prognoseverfahren auf die ersten Differenzen angewandt. Das Ergebnis sind prognostizierte Differenzwerte

$$\hat{y}_{t+1}^D = f(y_t^D), \forall t = 2 \dots T$$

Als erster Prognosewert in Periode $t = 2$ dient wiederum der erste Differenzwert: $\hat{y}_2^D = y_2^D$. Da die Bildung von Differenzen über Perioden erfolgt, kann für Periode $t = 1$ kein Prognosewert existieren.

Im *dritten Schritt* lassen sich die originären Zeitreihenwerte und die prognostizierten Differenzwerte additiv zu einem integrierten Prognosewert zusammenfassen. Die daraus resultierende integrierte Zeitreihe dient als trend- oder saisonbereinigte Vorhersagereihe. Die integrierten Prognosewerte berechnen sich nach:

$$\hat{y}_{t+1} = y_t + \hat{y}_{t+1}^D, \forall t = 1 \dots T$$

4.3.5 Resampling der Datenmenge eingedenk der Lags der Merkmale (X und Y)

Für ein LSTM-Netz müssen die Daten restrukturiert werden. Man spricht von einem *Resampling*. Beim Resampling wird die gesamte Datenmenge derart umorganisiert, dass ein Datensatz (Sample, Zeile einer Datentabelle) mehrere Perioden, sog. timesteps, und somit mehrere Werte der einzelnen Features je Periode umfasst. Die Anzahl an Perioden, mit der die Datenmenge umorganisiert werden muss, kann einer vorgelagerten ARIMA(X)-Analyse entnommen werden. Dies ist jedoch nicht zwingend erforderlich, denn die Anzahl an Perioden kann auch sachlogischen Überlegungen entspringen.

4.3.6 Partitionierung

Üblicherweise wird die gesamte Datenmenge in eine Trainings- und eine Testdatenmenge aufgespaltet. Dabei werden circa 70-80% der gesamten Datenmenge für die Trainingsdatenmenge und die verbleibenden 20-30% für die Testdatenmenge verwendet. Mithilfe der Trainingsdatenmenge wird das Modell erstellt (‘trainiert’), d.h. die modellbezogenen Parameterwerte wie Koeffizienten Werte bei Regressionsmodellen und Gewichtswerte bei künstlichen neuronalen Netzen ermittelt. Anschließend werden auf der Grundlage des erstellten Modells mit sowohl der Trainingsdatenmenge als auch der Testdatenmenge Prognosen angestrengt, mit anderen Worten: das Modell wird angewandt. Die Verwendung der Trainingsdatenmenge zu Prognosezwecken wird im Englischen auch als *in-sample forecast*, die Verwendung der Testdatenmenge als *out-of-sample forecast* bezeichnet. Diese

²² Vgl. Carlberg Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que. (2013: 138).

Bezeichnungen rühren daher, dass die Trainingsdaten dem Modell bekannt und daher in-sample sind, die Testdaten hingegen unbekannt und daher out-of-sample. Bei der Aufspaltung der gesamten Datenmenge in eine Trainings- und Testdatenmenge muss unterschieden werden, ob es sich bei den Daten um Zeitreihen handelt oder nicht. Handelt es sich nicht um Zeitreihendaten, so werden üblicherweise die Datensätze der gesamten Datenmenge zufallsbestimmt neu geordnet und anschließend in eine Trainings- und Testdatenmenge unterteilt. Liegen hingegen Zeitreihendaten vor, darf die Reihenfolge der Datensätze der gesamten Datenmenge nicht neu geordnet und somit durcheinandergebracht werden, da Zeitreihen eine inhärente chronologische Reihenfolge besitzen. Am Aufteilungsverhältnis ändert sich nichts.

4.3.7 Skalierung / Normalisierung

Für gewöhnlich werden metrische Größen in der Datenmenge einer Skalierung unterzogen. In der Mathematik benennt Skalierung die Begrenzung des Wertebereichs einer Variablen. Eine Skalierung sollte immer dann in Erwägung gezogen werden, falls sich die Werte der einzelnen metrischen Variablen oder Merkmale einer Datenmenge stark unterscheiden. Ein solch starker Unterschied liegt beispielsweise vor, falls die Werte der einen Größe zwischen 1 bis 10 und die einer anderen Größe zwischen 500 und 1000 liegen. Durch eine Skalierung werden die Größen hinsichtlich ihrer Ausprägungen vergleichbar und üben keinen unterschiedlich schwachen bzw. starken Einfluss mehr alleine aufgrund ihres niedrigen bzw. hohen Wertes auf eine endogene Größe (Y) aus. Um die skalierten Werte später wieder in ihren ursprünglichen Wertebereich zurückzusetzen, sind entsprechend gegenläufigen Funktionen anzuwenden. Dieser Vorgang wird als Rückskalierung bezeichnet.

Die Normalisierung stellt einen wichtigen Schritt in der Vorverarbeitung von Daten dar, um die verschiedenen Merkmale im Datensatz auf eine gemeinsame Skala zu bringen und sicherzustellen, dass keine einzelne Variable den Lernprozess dominiert. In dem Lastprognosemodell werden Normalisierungstechniken angewandt, um die Skalierung der Kalender- und Wetterdaten zu ermöglichen. Konkret wird die Min-Max-Normalisierungsmethode verwendet, welche die Daten auf einen vorher festgelegten Bereich (üblicherweise zwischen 0 und 1) umskaliert. Diese Normalisierungstechnik bewahrt die relativen Beziehungen zwischen den Datenpunkten und verhindert mögliche numerische Verzerrungen im Modell aufgrund der Größenordnung der Merkmale. Durch die Normalisierung der Daten wird sichergestellt, dass jedes Merkmal proportional zum Trainingsprozess des Lastprognosemodells beiträgt.

5 Überblick und theoretische Grundlagen zu künstlicher Intelligenz

5.1 Ursprung und Definition von künstlicher Intelligenz

Das vorliegende Kapitel widmet sich der Fragestellung, was genau unter KI zu verstehen ist, und grenzt dabei eine wissenschaftlich ausgeprägte Perspektive von einer praktisch orientierten Sichtweise auf KI

ab.²³ Darauf aufbauend werden gängige Klassifikationsmöglichkeiten von KI aufgezeigt und punktuell einige Typen von KI mathematisch genauer beleuchtet.

Die Forschung der künstlichen Intelligenz, im Englischen artificial intelligence (AI), blickt mittlerweile auf eine lange Tradition zurück. Vom 19. Juni bis 16. August des Jahres 1956 fand am Dartmouth College in Hanover, New Hampshire das *Dartmouth Summer Research Project on Artificial Intelligence* statt. Dieser auch als Dartmouth Konferenz bezeichnete Workshop schrieb Geschichte, da er als die Geburtsstunde der künstlichen Intelligenzforschung gilt. Führende Köpfe der Kognitionspsychologie sowie der Computer- und Sprachwissenschaft, namentlich u.a. John McCarthy (1927-2011, Informatiker), Marvin Minsky (1927-2016, Mathematiker), Allen Newell (1927-1992, Informatiker und Kognitionspsychologe), Claude Shannon (1916-2002, Mathematiker und Elektrotechniker), Nathaniel Rochester (1919-2001, Elektrotechniker), Herbert Alexander Simon (1916-2001, Politik- und Sozialwissenschaftler) und Noam Chomsky (1928-, Linguist) waren daran beteiligt. Die Motivation zu dieser Konferenz beschrieben McCarthy et al. bereits im August 1955 im Förderantrag²⁴, demzufolge das Ziel der KI ist, Maschinen zu entwickeln, die sich verhalten, als verfügten sie über Intelligenz.²⁵

Für eine exakte Definition von künstlicher Intelligenz erscheint es angebracht, die Wortbestandteile genauer zu betrachten. Das Adjektiv *künstlich* steht für ein von Menschenhand geschaffenes Artefakt, i.d.R. eine Maschine. Für das Konstrukt *Intelligenz*, einer der Schlüsselbegriffe der Psychologie, existiert eine Vielzahl an Definitionen mit unterschiedlichen Akzentuierungen.²⁶ Eine verbreitete Definition von Intelligenz stammt vom US-amerikanischen Psychologen David Wechsler und benennt „die zusammengesetzte oder globale Fähigkeit des Individuums, zweckvoll zu handeln, vernünftig zu denken und sich mit seiner Umgebung wirkungsvoll auseinanderzusetzen“.²⁷ Fasst man hingegen alle Facetten gängiger Definitionen zusammen, so lässt sich (menschliche) Intelligenz als die Fähigkeit und Fertigkeit interpretieren, Informationen durch sinnliche, geistige und emotionale Wahrnehmung zu verarbeiten und zu verstehen, dabei verschiedene Denkprozesse und Denkweisen (rational, kreativ, analog, intuitiv) anzuwenden, Problemlösungen zu finden, um sich an sich ändernde Gegebenheiten anpassen und sich für die Erlangung neuen Wissens motivieren zu können.

Überträgt man diese Definition von menschlicher Intelligenz auf Maschinen, so stellt man schnell fest, dass eine Maschine nicht annähernd über all diese Fähigkeiten und Fertigkeiten verfügt. Unter künstlicher Intelligenz versteht man Systeme (Agenten), die ihre Umgebung rational wahrnehmen, d.h. regelbasiert Daten verarbeiten, und darauf basierende Maßnahmen einleiten, um vorgegebene Ziele zu

²³ Vgl. Schneider, S., Loza, I., (2023). Einführung und Übersicht zu KI. In: T. Hochscherf, & M. Lätzel: KI und Kultur - Chimäre oder Chance. 2023.

²⁴ Vgl. McCarthy, J. / M. L. Minsky / N. Rochester / C. E. Shannon. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. 1955. <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>.

²⁵ Vgl. Ertel, W. (2016). Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung. 4. Aufl., 2016. Wiesbaden: Springer

²⁶ Vgl. Sternberg, R. J., & Salter, W. (1982): Conceptions of intelligence. In: Sternberg, R. J. (Ed.): Handbook of Human Intelligence. 1982, 3-121. Cambridge: Cambridge University Press.

²⁷ Vgl. Wechsler, D. (1964). Die Messung der Intelligenz Erwachsener. 3. Aufl. 1964. Bern: Huber.

erreichen.²⁸ Der Bezug auf eine rein rationale Arbeitsweise, im Sinne der psychologischen Denkforschung auf ein rein konvergentes Denken (rationales Denken), erscheint zwingend. Der Begriff der KI wird jedoch häufig ohne Rückgriff auf den Rationalitätsbegriff definiert. In noch umfassenderer Weise beschreibt KI den Versuch der Nachbildung menschlicher Intelligenz durch eine Maschine mithilfe einer Vielzahl von Daten, aus denen sie Muster ableitet und lernt. Diese Definition von KI, nämlich als Fähigkeit von Maschinen, menschliche Intelligenz zu mimen, ist zwar bei Praktikern weit verbreitet, im Grunde aber irreführend. Maschinen können keine menschlichen Fähigkeiten und Fertigkeiten umfassend nachahmen, da sie im Sinne der psychologischen Denkforschung keine divergenten Arbeitsweisen (analoges, kreatives und intuitives Denken) beherrschen.

5.2 KI-Typen

KI-Systeme lassen sich nach vielfältigen orthogonalen Kriterien klassifizieren. Die nachfolgende Abbildung bietet eine Übersicht über die in diesem Artikel behandelten Arten einer KI.

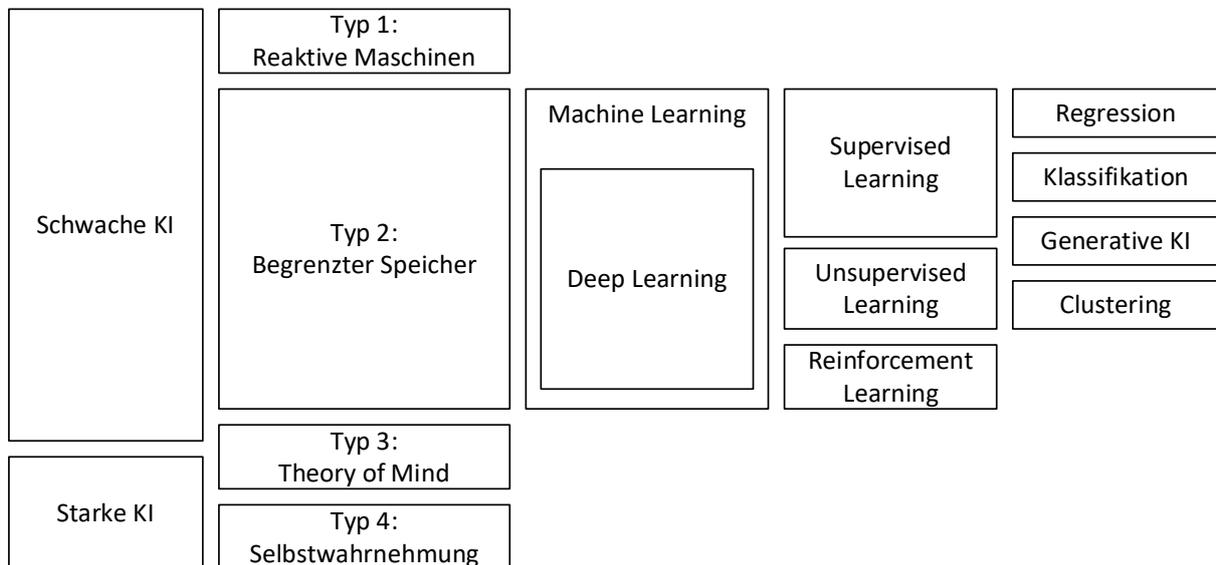


Abbildung 7: Klassifikationstypen an KI

Starke vs. schwache KI

Einer auf philosophischen Einschätzungen basierenden Anschauung nach können KI-Systeme in schwache KI (weak AI) und starke KI (strong AI) unterschieden werden.²⁹ Schwache KI ahmt intelligentes Verhalten nach, damit wirkt sie so, als sei sie intelligent. Im Gegensatz hierzu wird einer starken KI unterstellt, dass sie tatsächlich intelligent sei. Eine derartige KI wurde bis heute noch nicht entwickelt.

²⁸ Vgl. Russell, S. J., & Norvig, P. (2021): Artificial Intelligence: A Modern Approach. 4rd ed., 2021. Hoboken: Pearson Education.

²⁹ Vgl. Russell, S. J., & Norvig, P. (2021): Artificial Intelligence: A Modern Approach. 4rd ed., 2021. Hoboken: Pearson Education.

5.3 Vier Grundtypen

Einer weiteren und häufig anzutreffenden Klassifikation nach kann KI in vier Grundtypen unterteilt werden:³⁰

5.3.1 Typ 1: Reaktive Maschinen (Reactive machines)

Die erste und einfachste Art von KI ist ein System, das rein reaktiv ist. Es kann die Umgebung wahrnehmen und in Form hinterlegter Regeln und Prognosen bestimmte Aktivitäten durchführen. Es besitzt kein Gedächtnis bzw. keinen Speicher, kann also nicht auf frühere Erfahrungsdaten zurückgreifen und daraus lernen. Als Beispiel wird Deep Blue, ein Schachprogramm, genannt, das im Jahr 1996 den damals amtierenden Schachweltmeister Garri Kasparow besiegte.

5.3.2 Typ 2: Begrenzter Speicher (Limited memory)

Diese KI-Systeme verfügen über ein Gedächtnis bzw. einen Speicher, können demnach aus vergangenheitsbezogenen Daten lernen, um künftige Entscheidungen zu treffen. Die meisten KI-Systeme heutzutage gehören zu diesem Typ.

5.3.3 Typ 3: Theorie des Geistes (Theory of mind)

Für den dritten KI-Typ wird auf das aus der Psychologie bekannte Konzept der Theorie des Geistes zurückgegriffen, dessen Wurzeln bis weit in die Geschichte der Philosophie zurückreichen. Diese Theorie beschreibt die Fähigkeit eines Menschen, anhand des beobachtbaren Verhaltens einer Person Rückschlüsse auf deren mentale Zustände (Gedanken, Absichten, Erwartungen, Wünsche, Emotionen usw.), die sich einem unmittelbaren Zugang entziehen, zu ziehen und daraus das Verhalten zu erklären wie auch vorherzusagen.³¹ KI-Systeme, die diese Fähigkeit besitzen, sind sozial interaktionsfähig und könnten den Menschen ungeachtet seiner Selbstwahrnehmung ersetzen. Derartige Typen existieren noch nicht.

5.3.4 Typ 4: Selbstwahrnehmung (Self-awareness)

KI-Systeme des vierten Typs sind selbstreflektierend und können über alle Fähigkeiten der bisherigen Typen hinaus ihre eigene Existenz in ihre Verarbeitungs- und Entscheidungsprozesse einbeziehen, was ihnen im Grunde ein Bewusstsein verleiht. Auch dieser Typ von KI existiert noch nicht.

5.4 Supervised vs. unsupervised Learning

Lernende KI-Systeme betrachten Problemstellungen aus funktionaler Sicht $\hat{y} = f(y, x, p)$. Entsprechend dem statistischen Skalenniveau von y bzw. \hat{y} können zwei Arten von KI-Systemen

³⁰ Vgl. Hintze, A. (2016). Understanding the Four Types of Artificial Intelligence. 2016.

<https://www.govtech.com/computing/understanding-the-four-types-of-artificial-intelligence.html>.

³¹ Vgl. Baron-Cohen, S. (1991). Precursors to a theory of mind: Understanding Attention in Others. In Whiten, A (Ed.): Natural Theories of Mind: Evolution, Development, and Simulation of Everyday Mindreading. 1991, 233-251. Oxford, UK Cambridge, Massachusetts: B. Blackwell.

unterschieden werden. Ist \hat{y} metrisch, so resultieren KI-Systeme vom Typ Regression. Ist \hat{y} nicht-metrisch, also nominal oder ordinal, so wird von KI-Systemen vom Typ Klassifikation gesprochen. Anhand von y lässt sich eine weitere bekannte Unterteilung vornehmen. Sind tatsächliche Ergebnisse y vor dem Lernen gegeben, so spricht man von einem überwachten Lernen (supervised learning).³² Sind solche Ergebnisse nicht gegeben, ist von einem unüberwachten Lernen (unsupervised learning) die Rede.³³ In diesem Fall ($y = \emptyset$) erzeugen KI-Systeme aus der Trainingsmenge x die Ergebnisse \hat{y} selbst. Je nach relativer Konstanz oder Variabilität der resultierenden Ergebnisstruktur im Rahmen des unüberwachten Lernens lassen sich diese KI-Systeme weiter untergliedern. Bei parametrisierten Algorithmen für ML-Systeme bleibt die Ergebnisstruktur \hat{y} bei gegebenen Features x , aber variierenden Featurewerten, konstant.³⁴

5.5 Machine Learning und Deep Learning

5.5.1 Kurze Einführung und mathematische Grundlegung

KI-Systeme vom Typ 2 sind lernende Systeme und lassen sich somit der Klasse Machine Learning (ML) zuordnen. Eine klassische Definition von Machine Learning stammt vom US-amerikanischen Informatiker Tom Mitchell: „A computer program is said to learn from experience E with respect to some class of tasks T and performance measure P , if its performance at tasks in T , as measured by P , improves with experience E “³⁵. Zu einem KI-System der Klasse ML gehören eine Trainingsmenge, eine Zielfunktion und ein Lernalgorithmus.³⁶ Die Trainingsmenge muss sowohl direktes als auch indirektes Feedback fürs Lernen geben. Ein direktes Feedback bezieht sich auf die Merkmale oder Features x der Trainingsmenge, während ein indirektes Feedback durch die Ergebnisse des Systems \hat{y} möglich ist. Darüber hinaus muss die Trainingsmenge eine gewisse Flexibilität aufweisen, mit der Folge, dass das KI-System mit variierenden Trainingsmengen gleichermaßen gut klarkommt. Und zu guter Letzt soll die Trainingsmenge die Aufgaben- oder Problemstellung geeignet repräsentieren. Die Zielfunktion beantwortet die Fragen, was gelernt werden soll und wie das Gelernte eingedenk gegebener weiterer Parameter p bestimmt wird. Formal lässt sich die Zielfunktion wie folgt darstellen: $\hat{y} = f(x, p)$ mit $x \in R^n, p \in R^m$. Der Lernalgorithmus erfüllt die Aufgaben der Parameterschätzung und -anpassung. Der Parameterschätzung liegt eine Abweichungs- oder Fehlerfunktion $E(f(x, p), y)$ mit $y \in R^k$ zugrunde, mit der sich Unterschiede zwischen den Ergebnissen des Systems \hat{y} und den tatsächlich vorliegenden Ergebnissen y bestimmen lassen. Die Parameteranpassung wird mittels einer Optimierungsvorschrift $\text{opt}\phi(E(f(x, p), y))$ erreicht.

³² Vgl. Russell, S. J., & Norvig, P. (2021): Artificial Intelligence: A Modern Approach. 4rd ed., 2021. Hoboken: Pearson Education.

³³ Vgl. Russell, S. J., & Norvig, P. (2021): Artificial Intelligence: A Modern Approach. 4rd ed., 2021. Hoboken: Pearson Education.

³⁴ Vgl. Russell, S. J., & Norvig, P. (2021): Artificial Intelligence: A Modern Approach. 4rd ed., 2021. Hoboken: Pearson Education.

³⁵ Vgl. Mitchell, T. (1997). Machine Learning. 1997. New York et al.: McGraw-Hill.

³⁶ Vgl. Mitchell, T. (1997). Machine Learning. 1997. New York et al.: McGraw-Hill.

Eine Teilmenge des ML ist Deep Learning (DL). Selbst wenn dieser Ausdruck mit tiefem Lernen übersetzt werden kann, ist die englische Sprechform die geläufige Ausdrucksweise. Deep Learning steht allgemein für eine besondere Form von künstlichen neuronalen Netzen.³⁷ Eine beispielhafte Darstellung eines künstlichen neuronalen Netzes findet sich in der nachfolgenden Abbildung.

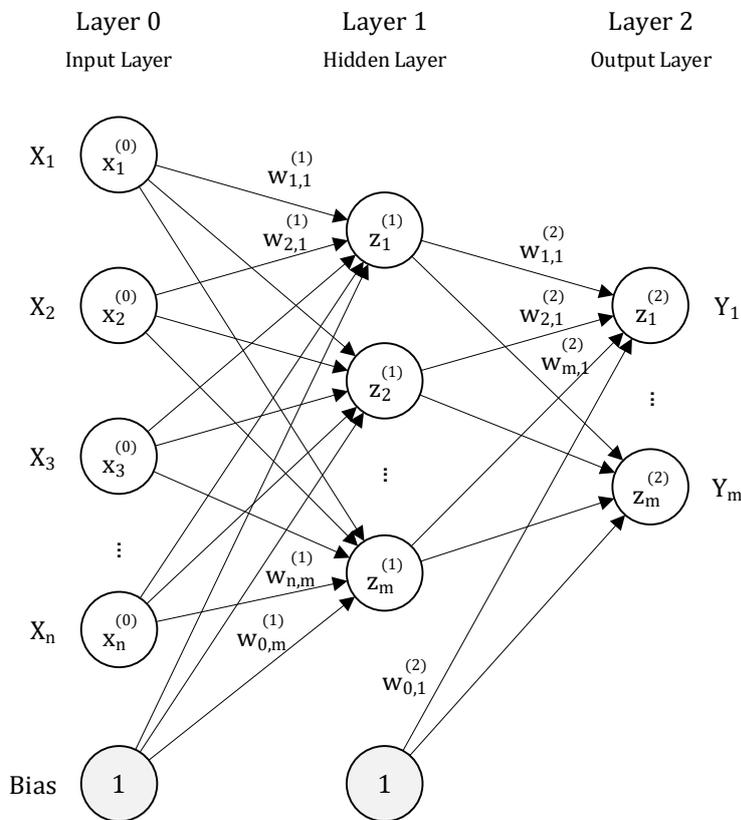


Abbildung 8: Schematische Darstellung eines künstlichen neuronalen Netzes

Diese Netze bestehen aus einer Vielzahl an Schichten mit jeweiligen Knoten, auch als Units bezeichnet. Eine Unit erhält Daten von Units der vorangegangenen Schicht, verarbeitet diese und reicht das Ergebnis an die Units der nachfolgenden Schicht weiter. Die Tiefe eines künstlichen neuronalen Netzes wird durch die Anzahl der Schichten bestimmt, ihre Breite durch die maximale Anzahl der Units der stärksten Schicht. Die in der Abbildung links dargestellte Schicht ist die Eingabeschicht (Input Layer). Sie besitzt keine Verarbeitungsvorschriften und dient als passiver Datenlieferant. Sie wird nachfolgend mathematisch dargestellt.

Auf Ebene der Merkmale:
$$X = \{X_1, \dots, \dots, X_n\}$$

Auf Ebene der Ausprägungen:
$$x = [\dots, \dots, x_i, \dots, x_n], x \in \mathbb{R}^n$$

mit

³⁷ Vgl. Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. In: Neural Networks, 61 (2015), 85-117.; Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014): Generative Adversarial Nets. In: Proceedings of the International Conference on Neural Information Processing Systems (NIPS) 2014, pp. 2672-2680.

- X Menge an Input-Units.
- X_i i-te Input-Unit.
- x Vektor an Werten der Input-Units.
- x_i Wert der i-ten Input-Unit.

Liegen pro Input-Unit mehrere Werte vor, so muss ein neues Subskript $r = 1..s$ ³⁸ den entsprechenden Wert im Werte-Vektor wiedergeben.

...

mit

- $x_{r,i}$ Wert des r-ten Merkmalsträgers oder zum Zeitpunkt r der i-ten Input-Unit.

Der Vektor x_i wird in transponierter Form x_i^T notiert, um einen Spaltenvektor darzustellen. Diese Form eignet sich, um die Werte eines Eingabemerkmals bzw. einer Input-Unit darzustellen. Möchte man alle Werte aller Eingabemerkmale darstellen, so lässt sich die Matrix-Schreibweise verwenden. In diesem Fall ist der verwendete Buchstabe X überladen, da er sowohl auf Ebene der Merkmale als auch auf Ebene der Merkmalswerte Anwendung findet. Alle Werte aller Eingabemerkmale, auch Featuremenge genannt, lässt lassen sich wie folgt notieren:

$$X = [x_{r,i}]^T \forall i = 1..n, r = 1..s, X \in \mathbb{R}^{s \times n}$$

Die Eingabeschicht nimmt eine besondere Stellung ein, da ihre Units über kein Innenleben verfügen. Das heißt, sie selbst nehmen keinen Input entgegen und verarbeiten diesen durch eine Kombination aus Propagierung und Aktivierung, vielmehr ist ihr Ergebnis bzw. Output vorgegeben. Sie dienen als passiver Datenlieferant für die nachfolgende Schicht, z.B. die erste Hidden-Schicht.

Der Index i denotiert eine sendende Unit und der Index j eine empfangende Unit.

$$w_j^{(l)} = \begin{bmatrix} w_{1,j}^{(l)} \\ \vdots \\ w_{i,j}^{(l)} \\ \vdots \\ w_{n,j}^{(l)} \end{bmatrix}, \forall j = 1..m^{(l)}$$

mit

³⁸ r steht für row (Zeile), s für sample (insgesamte Anzahl an Datensätzen).

$w_j^{(l)}$ Vektor an Gewichtswerten im n -dimensionalen reellen Vektorraum: $w_j^{(l)} \in \mathbb{R}^n$.

Ein Element $w_{i,j}^{(l)}$ benennt einen Gewichtswert von Unit i zur Unit j im Layer l .

Das Subskript i benennt eine sendende Unit und j eine empfangende Unit. Das Superscript l benennt den l -ten Layer.

j j -te empfangende Unit; mit $m^{(l)}$ empfangenden Units im Layer l .

$w_{i,j}^{(l)}$ Wert des Gewichts von der Unit i zur Unit j im Layer l .

Im Gegensatz zu den Input-Units werden die Hidden-Units nicht explizit benannt. Man könnte zwar eine bestimmte Hidden-Unit in einem Layer l mit $H_j^{(l)}$ benennen, jedoch wird im weiteren Verlauf darauf verzichtet, da die Angabe der alleinigen Indizes j und l ausreichen, um eben jene Hidden-Unit zu identifizieren.

Ähnliches gilt für die Gewichte, weshalb auch hier keine symbolische Unterscheidung zwischen dem Merkmal Gewicht und der Merkmalsausprägung Gewichtswert gemacht werden soll. Allgemein könnte man ein bestimmtes Gewicht von einer Unit i zu einer Unit j in einem bestimmten Layer l mit $W_{i,j}^{(l)}$ bezeichnen, also mit einem Großbuchstaben. Da sie jedoch keine expliziten Namen außer eben allgemein Gewicht besitzen, wird im weiteren Verlauf darauf verzichtet, sie als Merkmal zu symbolisieren.

Eine verdeckte Schicht besteht aus $m^{(l)}$ Hidden-Units, wobei m je Hidden-Layer variieren kann. Zum Beispiel kann der erste Hidden-Layer drei Hidden-Units ($m = 3$) und der zweite Hidden-Layer eine Hidden-Unit ($m = 1$) umfassen.

Berücksichtigt man sämtliche Hidden-Units je Hidden-Layer, so ist die gesamte Gewichtswertematrix eines einzelnen Hidden-Layers l :

$$W^{(l)} = \begin{bmatrix} w_{1,1}^{(l)} & \cdots & w_{1,m}^{(l)} \\ \vdots & w_{i,j}^{(l)} & \vdots \\ w_{n,1}^{(l)} & \cdots & w_{n,m}^{(l)} \end{bmatrix}$$

Der Großbuchstabe W entspricht der Matrix-Schreibweise. Die Matrix hat eine Höhe von n und eine Breite von m , notiert mit $W \in \mathbb{R}^{n \times m}$.

Eine Unit j erhält Ergebniswerte in Form eines Eingabevektors als Input. Diese Werte werden zuerst mittels f_{prop} propagiert und das daraus resultierende Ergebnis anschließend mittels f_{act} aktiviert, was zum finalen Output der Unit führt. Die Verkettung der beiden Funktionen ist nachfolgend dargestellt.

$$z_j^{(l)} = \left(f_{act,j}^{(l)} \circ f_{prop,j}^{(l)} \right) (z^{(l-1)}) = f_{act,j}^{(l)} \left(f_{prop,j}^{(l)} (z^{(l-1)}) \right), \forall j = 1..m^{(l)}, l = 1..L$$

mit

$z_j^{(l)}$ Ergebnis von Unit j im Layer l .

$f_{prop,j}^{(l)}$ Propagierungsfunktion der Unit j im Layer l .

$f_{act,j}^{(l)}$ Aktivierungsfunktion der Unit j im Layer l .

$z^{(l-1)}$ Ergebnisvektor aus dem Layer $l - 1$.

$m^{(l)}$ Anzahl an Units im Layer l .

L Anzahl an Schichten ohne Eingabeschicht.

Aus der Formel lässt sich ableiten, dass die Eingabeschicht den Index $l = 0$ besitzt. Die Ergebniswerte dieser Schicht lassen sich als Vektor formal wie folgt notieren:

$$\dots = (x_1^{(0)}, \dots, x_i^{(0)}, \dots, x_{n^{(0)}}^{(0)})$$

Allgemein lässt sich der Vektor der Ergebniswerte einer Schicht l wie folgt notieren:

$$z^{(l)} = (\dots, \dots, z_j^{(l)}, \dots, z_{m^{(l)}}^{(l)}), \forall l = 1..L$$

In einem mehrschichtigen Netz wird ein Hidden-Layer zum Input-Layer für die jeweils unmittelbar nachgelagerte Schicht.

Die Units der versteckten und der Ausgabeschicht bestehen aus jeweils drei hintereinander geschalteten mathematischen Funktionen: der Propagierungsfunktion, der Aktivierungsfunktion und der Output-Funktion.³⁹ Die Propagierungsfunktion errechnet eine gewichtete Summe der Inputs der vorangelaagerten Units. Der von Unit i aus Schicht j übergebene Wert x_{ij} wird mit dem Gewicht w_{ij} multipliziert, und alle diese Produkte werden addiert. $f_{prop,j}^{(l)} = \sum_{i=1}^{n^{(l-1)}} w_{i,j}^{(l)} \cdot z_i^{(l-1)} + w_{0,j}^{(l)} \cdot 1$

mit

$n^{(l-1)}$ Anzahl an Units im Layer $l - 1$.

$z_i^{(l-1)}$ Ergebnis von Unit i im Layer $l - 1$.

³⁹ Vgl. Haykin, S. S. (2009). Neural Networks and Learning Machines. 3. ed., 2009. Upper Saddle River: Pearson Education.

$w_{i,j}^{(l)}$ Wert des Gewichts von der Unit i Zzur Unit j im Layer l .

$w_{0,j}^{(l)} \cdot 1$ Gewichtswert von Bias-Unit ($i = 0$) zur Unit j im Layer l . Der Faktor 1 steht für den konstanten Wert der Bias-Unit, d.h. $z_0^{(l-1)} = 1$.

Neben der Standardpropagation existieren noch weitere Propagierungsfunktionen, die den Units entsprechende Namen verleihen. Nachfolgend werden die Propagierungen einer Pi- und einer Sigma-Pi-Unit dargestellt.

Eine Pi-Unit j im Layer l wird wie folgt propagiert:

$$f_{prop,j}^{(l)} = \sum_{i=1}^{n^{(l-1)}} w_{i,j}^{(l)} \cdot \prod_{k=1}^K z_{i,k}^{(l-1)} + 1 \cdot w_{0,j}^{(l)}$$

Eine Sigma-Pi-Unit j im Layer l als Polynom des Grades G wird wie folgt propagiert:

$$f_{prop,j}^{(l)} = \sum_{g=1}^G \sum_{i=1}^{n^{(l-1)}} \left[w_{i,j}^{g(l)} \cdot z_i^{g(l-1)} \right] + 1 \cdot w_{0,j}^{(l)}$$

Die Aktivierungsfunktion übernimmt sodann das Ergebnis der Propagierungsfunktion und nimmt eine (nicht-)lineare Transformation dieses Ergebnisses vor.

Im nNachfolgenden werden die gängigsten Aktivierungsfunktionen vorgestellt. Das Argument x entspricht dem Ergebnis der Propagierungsfunktion, das auch als Netzeingabe bezeichnet wird.

Lineare Aktivierung

$$f_{act,j}^{(l)}(x) = x$$

Binäre Schwellenwert-Funktion

$$f_{act,j}^{(l)}(x) = \begin{cases} 1 & x \geq 0 \\ 0 & \text{sonst} \end{cases}$$

Rectifier Funktion

$$f_{act,j}^{(l)}(x) = \max(0, x)$$

Logistische Funktion

$$f_{act,j}^{(l)}(x) = \frac{1}{1+e^{-c \cdot x}}$$

Tangens-Hyperbolicus Funktion

$$f_{act,j}^{(l)}(x) = \frac{\sinh x}{\cosh x} = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1} = 1 - \frac{2}{e^{2 \cdot x} + 1}$$

Softmax-Funktion

$$f_{act,j}^{(l)}(x) = \frac{e^{x_j}}{\sum_{k=1}^K e^{x_k}}, \forall j = 1..K, x = (x_1, \dots, x_K) \in \mathbb{R}^K$$

Der Vektor x beinhaltet den Netzininput aller K Units, die einer Softmax-Aktivierung unterliegen. Ein Element dieses Vektors, x_k , entspricht dem Netzininput der k -ten Unit. Im Zähler wird x_k als Exponent verarbeitet, im Nenner die Summe der exponenzierten Netzeingaben. Eine Schicht mit Softmax-Aktivierung sieht demnach für jede einzelne Unit die Netzeingaben aller Units der Schicht.

Für die Standardpropagierung lässt sich das Ergebnis einer Unit j im Layer l allgemein notieren:

$$z_j^{(l)} = f_{act,j}^{(l)} \left(\sum_{i=1}^{n^{(l-1)}} z_i^{(l-1)} \cdot w_{i,j}^{(l)} + 1 \cdot w_{0,j}^{(l)} \right), \forall j = 1..m^{(l)}, l = 1..L$$

mit

$z_j^{(l)}$ Ergebnis von Unit j im Layer l .

$f_{act,j}^{(l)}$ Aktivierungsfunktion der Unit j im Layer l .

$n^{(l-1)}$ Anzahl an Units im Layer $l - 1$.

$z_i^{(l-1)}$ Ergebnis von Unit i im Layer $l - 1$.

$w_{i,j}^{(l)}$ Wert des Gewichts von der Unit i zur Unit j im Layer l .

$1 \cdot w_{0,j}^{(l)}$ Gewichtswert von Bias-Unit ($i = 0$) zur Unit j im Layer l . Der Faktor 1 steht für den konstanten Wert der Bias-Unit, d.h. $z_0^{(l-1)} = 1$.

$m^{(l)}$ Anzahl an Units im Layer l .

L Anzahl an Schichten ohne der Eingabeschicht.

Am Ende verarbeitet die Output-Funktion das Ergebnis der Aktivierungsfunktion. Das daraus resultierende finale Ergebnis wird dann an alle nachgelagerten Units weitergereicht, bis die Ergebnisse in der Ausgabeschicht vorliegen. Da die Output-Funktion i.d.R. die Identitätsfunktion ist, wird sie faktisch vernachlässigt. Somit reduzieren sich die mathematischen Funktionseinheiten einer Unit auf Propagierung und Aktivierung.

5.5.2 Convolutional Neural Network (CNN)

Ein Faltendes Neuronales Netzwerk, bzw. *Convolutional Neural Network* (CNN) ist eine Art neuronales Feedforward-Netzwerk, das ursprünglich 1998 von LeCun⁴⁰ entwickelt wurde. In der stetigen Weiterentwicklung im Bereich der KI haben CNNs eine herausragende Stellung eingenommen,

⁴⁰ LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86 (11), 2278–2324.

insbesondere in der Verarbeitung von Bildern, Audiodateien und eignen sich des Weiteren in der Verarbeitung natürlicher Sprache. Ferner können sie für die Vorhersage von Zeitreihen, da sie wichtige Features aus einem Datensatz extrahieren können, verwendet werden.⁴¹ Nachfolgend wird auf die Struktur, Funktionsweise und Anwendungen dieser Netzwerke eingegangen. CNNs sind eine spezielle Art von neuronalen Netzwerken, die darauf abzielen, räumlich lokale Muster in Daten zu identifizieren, indem sie geometrische Transformationen auf verschiedene Bereiche eines Eingabensensors anwenden.⁴² Diese Transformationen werden in Form von Faltungen durchgeführt, wodurch Repräsentationen entstehen, die translationsinvariant sind.⁴³ Dies ermöglicht eine dateneffiziente und modulare Verarbeitung von Informationen. Dieses Konzept lässt sich auf Räume beliebiger Dimensionalität anwenden, sei es auf eindimensionale Sequenzen, zweidimensionale Bilder, dreidimensionale Volumina und darüber hinaus.⁴⁴

CNNs setzen sich aus einer Abfolge von Convolutional- und Pooling-Layern zusammen. Die Convolutional-Layer bilden das Herzstück dieser Architektur und sind dafür zuständig, räumlich lokale Muster in den Daten zu erkennen. Durch die Anwendung von Faltungen auf Eingabensensoren werden relevante Informationen hervorgehoben und extrahiert. Dies führt dazu, dass CNNs in der Lage sind, auf Muster zu reagieren, unabhängig von deren Position im Bild.

Die Pooling-Layer ermöglichen ein räumliches Herunterrechnen der Daten. Dies ist notwendig, um sicherzustellen, dass die Größe der Feature-Maps nicht übermäßig anwächst, während die Anzahl der Merkmale zunimmt. Gleichzeitig ermöglichen die Pooling-Layer den nachfolgenden Convolutional-Layern, einen größeren räumlichen Bereich der Eingabedaten zu erfassen.

Die Struktur von CNNs endet typischerweise entweder mit einem sogenannten Flatten-Layer oder einem globalen Pooling-Layer. Ein Flatten-Layer wandelt räumliche Feature-Maps in Vektoren um, was die Grundlage für den nachfolgenden Dense-Layer bildet. In diesem Stadium können Klassifikations- oder Regressionsaufgaben durchgeführt werden, um die Daten zu interpretieren.

Die konventionelle Faltung in CNNs kann zunehmend durch die kanalweise trennbare Faltung ersetzt werden, insbesondere in zweidimensionalen Bildern. Diese Technik bietet eine äquivalente, aber schnellere Alternative zur herkömmlichen Faltung und zeichnet sich durch eine hohe Repräsentationsfähigkeit aus. Durch den Einsatz der kanalweisen trennbaren Faltung können kleinere und schnellere CNNs erstellt werden, die zudem eine verbesserte Performance aufweisen.

⁴¹Vgl. Lu, W., Li, J., Li, Y., Sun, A., Wang, J. (2020). A CNN-LSTM-Based Model to Forecast Stock Prices. *Complexity*.

⁴²Vgl. G Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.

⁴³Vgl. Chollet, F. (2018). *Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek*. Deutschland: MITP.

⁴⁴Vgl. Chollet, F. (2018). *Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek*. Deutschland: MITP.

5.5.3 Long Short-Term Memory (LSTM)

Die Fortschritte im Bereich der künstlichen Intelligenz tragen maßgeblich zur Weiterentwicklung von neuronalen Netzwerken zu. Diese Netze sind in der Lage komplexe Abhängigkeiten innerhalb von Sequenzen zu modellieren. Eines dieser leistungsstarken Modelle ist das Long Short-Term Memory (LSTM) Netzwerk, welches eine Unterkategorie der rekurrenten neuronalen Netzwerke (RNNs) darstellt.

Dieser Abschnitt liefert eine umfassende Übersicht über LSTM-Netzwerke und ihre Anwendungen, sowie eine Weiterentwicklung namens Bidirectional LSTM (BiLSTM), die noch tiefere Einblicke in die Modellierung von Sequenzen ermöglicht.

Die Forschung im Bereich neuronaler Netzwerke hat zur Entwicklung von Long Short-Term Memory (LSTM) Modellen geführt, die erstmals im Jahr 1997 von Hochreiter und Schmidhuber⁴⁵ entwickelt worden sind. Später wurden diese Modelle im Jahr 2000 von Gers et al.⁴⁶ und 2005 von Graves und Schmidhuber⁴⁷ weiterentwickelt. LSTM-Netzwerke sind spezielle rekurrente neuronale Netzwerke (RNN), die sich durch ihre Fähigkeit auszeichnen, vergangene Werte zu erinnern und für zukünftige Analysen zu nutzen. Ihr Einsatzgebiet erstreckt sich über verschiedene Bereiche, darunter die Verarbeitung natürlicher Sprache⁴⁸, Handschrifterkennung⁴⁹, zur Zeitreihenvorhersage⁵⁰ und die Prognose der Volatilität von Aktienindizes⁵¹.

Im Allgemeinen besteht ein LSTM-Netz aus einer Eingabeschicht, einer verborgenen Schicht und einer Ausgabeschicht mit mehreren Units pro Schicht. In jeder Unit gibt es drei Arten von Gates, die für die Filterung von Informationen und die Entscheidung zuständig sind, welche Informationen des Zellzustands c_t relevant sind und weitergegeben, angepasst oder gelöscht werden sollen. Das Forget-Gate löscht Informationen, die nicht mehr benötigt werden, oder behält wichtige Informationen aus einer früheren Periode. Daher werden die Aktivierungswerte f_t des Forget-Gates zunächst aus dem aktuellen Input x_t , dem Output der vorherigen Speicherzelle $h_{(t-1)}$ und dem Bias-Wert b_f gebildet. Die Sigmoid-Schicht skaliert diese Werte dann in den Wertebereich zwischen 0 und 1. Diese Zuordnung gibt an, wie viel Information aus dem Zellzustand gespeichert oder gelöscht werden soll. Werte, die nahe bei 0

⁴⁵ Vgl. Sepp Hochreiter und Jürgen Schmidhuber, „Long Short-Term Memory“, *Neural Computation* 9, Nr. 8 (1. November 1997): 1735–80, <https://doi.org/10.1162/neco.1997.9.8.1735>.

⁴⁶ Vgl. Felix A Gers, Jürgen Schmidhuber, und Fred Cummins, „Learning to forget: Continual prediction with LSTM“, *Neural computation* 12, Nr. 10 (2000): 2451–71.

⁴⁷ Vgl. Alex Graves und Jürgen Schmidhuber, „Frame-wise phoneme classification with bidirectional LSTM and other neural network architectures“, *Neural networks* 18, Nr. 5–6 (2005): 602–10.

⁴⁸ Vgl. Kanchan M Tarwani und Swathi Edem, „Survey on recurrent neural network in natural language processing“, *Int. J. Eng. Trends Technol* 48, Nr. 6 (2017): 301–4.

⁴⁹ Vgl. Alex Graves u. a., „A novel connectionist system for unconstrained handwriting recognition“, *IEEE transactions on pattern analysis and machine intelligence* 31, Nr. 5 (2008): 855–68.

⁵⁰ Vgl. Gers, Schmidhuber, und Cummins, „Learning to forget: Continual prediction with LSTM“; Hochreiter und Schmidhuber, „Long Short-Term Memory“.

⁵¹ Vgl. Nicolas Huck, „Pairs selection and outranking: An application to the S&P 100 index“, *European Journal of Operational Research* 196, Nr. 2 (2009): 819–25; Nowrouz Kohzadi u. a., „A comparison of artificial neural network and time series models for forecasting commodity prices“, *Neurocomputing* 10, Nr. 2 (1996): 169–81.

liegen, werden vergessen, während Werte, die sich 1 nähern, beibehalten werden sollten. Der Vektor f_t des Vergessenstors ist in der nachfolgenden Formel dargestellt. Mit σ wird die Sigmoidschicht bezeichnet, W steht für die Gewichtsmatrizen, f_t , i_t und o_t beschreiben die Vektoren der Aktivierungswerte der entsprechenden Gates, und c_t bezeichnet den Zellzustand.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) = \sigma(W_{hf} \cdot h_{t-1} + W_{xf} \cdot x_t + b_f)$$

Im nächsten Schritt wird entschieden, welche Informationen dem Zellzustand c_t hinzugefügt werden sollen. Zu diesem Zweck werden die entsprechenden Kandidaten \tilde{c}_t mit Hilfe einer tangentialen hyperbolischen Funktion nach der unteren Formel berechnet. Darüber hinaus bildet das Eingangsgatter einen Vektor i_t , der wie bei der Berechnung der f_t -Werte anhand einer Skalierung bestimmt, welche Kandidaten in den Zellzustand aufgenommen werden sollen.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) = \sigma(W_{hi} \cdot h_{t-1} + W_{xi} \cdot x_t + b_i)$$

$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) = \tanh(W_{hc} \cdot h_{t-1} + W_{xc} \cdot x_t + b_c)$$

Basierend auf den Daten, die durch das Forget-Gate und das Input-Gate geleitet werden, ändert sich der aktuelle Zustand der Zelle, was durch Formel (#) dargestellt werden kann.

$$c_t = (f_t \circ c_{t-1} + \tilde{c}_t \circ i_t)$$

Die Berechnung des Output-Gates erfolgt auf die gleiche Weise wie bei den vorherigen Gate-Berechnungen und ist in nachfolgender Formel dargestellt.

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) = \sigma(W_{ho} \cdot h_{t-1} + W_{xo} \cdot x_t + b_o)$$

Schließlich wird der aktuelle Output h_t bestimmt.

$$h_t = o_t \circ \tanh(c_t)$$

Die LSTM-Netze sind eine vielversprechende Technologie zur Verbesserung der Lastprognosegenauigkeit. Verschiedene Studien haben die Verwendung von LSTM-Netzen für die Lastprognose untersucht und gezeigt, dass sie eine bessere Vorhersagegenauigkeit im Vergleich zu herkömmlichen Machine-Learning-Modellen bieten können. Der Autor Kong und Kolleg:innen schlagen einen DL-basierten LSTM-Ansatz vor, der eine höhere Vorhersagegenauigkeit aufweist als herkömmliche maschinelle Lern- und empirische Modelle.⁵² In der Studie von Bouktif und Kolleg:innen wird ein DL-Modell mit LSTM für LF entwickelt, das mithilfe von einer *feature selection* bzw. Merkmalsauswahl und einem genetischen Algorithmus optimiert wird, um eine bessere

⁵² Vgl. Weicong Kong u. a., „Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network“, *IEEE Transactions on Smart Grid* 10, Nr. 1 (Januar 2019): 841–51, <https://doi.org/10.1109/TSG.2017.2753802>.

Vorhersagegenauigkeit als herkömmliche Modelle des maschinellen Lernens zu erreichen.⁵³ Die Autorengruppe Cheng und Kolleg:innen verwenden ebenfalls eine Merkmalsauswahl für einen realen öffentlichen Datensatz und finden heraus, dass das vorgeschlagene LSTM-Modell die Vorhersagegenauigkeit um bis zu 28,57 % in Bezug auf den mittleren quadratischen Fehler (MSE) im Vergleich zu Benchmark-Modellen verbessert.⁵⁴ Han und Kolleg:innen schlagen einen zyklusbasierten LSTM-Ansatz (C-LSTM) für STLF und mittelfristige Lastprognosen (MTLF) vor, der schneller trainiert wird und eine genauere Vorhersagequalität in Bezug auf den mittleren relativen Fehler (MRE) aufweist.⁵⁵ Andere Autoren wie Wang und Kolleg:innen⁵⁶, Bashir und andere⁵⁷ und Bedi/Toshniwal⁵⁸ verwenden Clustering-Techniken, kombinieren DL-Architekturen mit anderen maschinellen Lernmodellen oder verwenden LSTM mit Multi-Input-Multi-Output-Ansätzen, um eine bessere Vorhersagegenauigkeit zu erreichen.

Insgesamt deuten diese Studien darauf hin, dass LSTM-Netzwerke, Optimierungstechniken wie die Merkmalsauswahl und die Kombination von DL-Architekturen mit anderen maschinellen Lernmodellen und Clustering-Techniken die Leistung von LF-Modellen verbessern können. Außerdem hat sich der C-LSTM-Ansatz als effizienter für STLF und MTLF erwiesen.

Obwohl LSTM-Netzwerke bereits eine bedeutsame Weiterentwicklung gegenüber herkömmlichen RNNs darstellen, geht die Entwicklung weiter voran. Die Einführung von Bidirectional LSTM (BiLSTM) erweitert die Modellierungsfähigkeiten signifikant, indem es die Sequenzen sowohl vorwärts als auch rückwärts analysiert. Diese bidirektionale Verarbeitung gestattet es dem Modell, sowohl vergangene als auch zukünftige Kontexte bei der Modellierung zu berücksichtigen. Insbesondere in der natürlichen Sprachverarbeitung erweist sich dieser Ansatz als äußerst hilfreich, um die komplexen Abhängigkeiten zu erfassen, die in beiden Richtungen auftreten.

Die BiLSTM-Architektur kombiniert zwei separate LSTMs, die jeweils vorwärts und rückwärts arbeiten. Die Ausgaben dieser LSTMs werden harmonisiert, um ein tiefes Verständnis der gesamten Sequenz zu erlangen. Dies befähigt das Modell, sowohl lokale als auch globale Muster zu erkennen und komplexe Abhängigkeiten überzeugend abzubilden.

⁵³ Vgl. Salah Bouktif u. a., „Optimal Deep Learning LSTM Model for Electric Load Forecasting Using Feature Selection and Genetic Algorithm: Comparison with Machine Learning Approaches“, *Energies* 11, Nr. 7 (22. Juni 2018): 1636, <https://doi.org/10.3390/en11071636>.

⁵⁴ Vgl. Yao Cheng u. a., „PowerLSTM: power demand forecasting using long short-term memory neural network“, in *Advanced Data Mining and Applications: 13th International Conference, ADMA 2017, Singapore, November 5–6, 2017, Proceedings 13* (Springer, 2017), 727–40.

⁵⁵ Vgl. Lingyi Han u. a., „Enhanced Deep Networks for Short-Term and Medium-Term Load Forecasting“, *IEEE Access* 7 (2019): 4045–55, <https://doi.org/10.1109/ACCESS.2018.2888978>.

⁵⁶ Vgl. Yi Wang u. a., „Probabilistic Individual Load Forecasting Using Pinball Loss Guided LSTM“, *Applied Energy* 235 (Februar 2019): 10–20, <https://doi.org/10.1016/j.apenergy.2018.10.078>.

⁵⁷ Vgl. Tasarruf Bashir u. a., „Short Term Electricity Load Forecasting Using Hybrid Prophet-LSTM Model Optimized by BPNN“, *Energy Reports* 8 (November 2022): 1678–86, <https://doi.org/10.1016/j.egy.2021.12.067>.

⁵⁸ Vgl. Jatin Bedi und Durga Toshniwal, „Deep Learning Framework to Forecast Electricity Demand“, *Applied Energy* 238 (März 2019): 1312–26, <https://doi.org/10.1016/j.apenergy.2019.01.113>.

5.6 Autoregressive Modelle

Auf Basis empirischer Studien⁵⁹ haben Box/Jenkins in den 1960er Jahren die Methodik ARIMA entwickelt und durch ihren praxisorientierten Ansatz populär gemacht.⁶⁰ Die erste Arbeit zum autoregressiven Teilmodell (AR) und zu Moving Average (MA) stammt von Peter Whittle aus dem Jahr 1951.⁶¹

Das Akronym **ARIMA** steht für:⁶²

- **AR: Aurorerssive.** Das Prognosemodell kann gänzlich oder in Teilen auf Autoregression basieren.
- **I: Intergrated.** Die Zeitreihe (Baseline; beobachtete Werte) muss eventuell in verschiedene Serien aufgespalten werden. Wenn es nun zu Prognosen kommt, müssen die Teile wieder zusammengeführt – sprich: integriert – werden. Die Zeitreihe wird wieder in ihren originären Zustand zurückversetzt.
- **MA: Moving Average.** Obwohl hier von "Moving Averages" gesprochen wird, so sind hier nicht die aus Kapitel **Error! Reference source not found.** bekannten gleitenden Durchschnitte, sondern die Durchschnitte der Schätzfehler gemeint. Fehler sind die Differenzen zwischen den Beobachtungswerten und den Prognosewerten.

Allgemeine ARIMA-Notation: $ARIMA(p, d, q)$ mit

- p = Anzahl an autoregressiven Parametern (Werten) im Modell, d. h. die Anzahl an Lags
- d = Anzahl an aufgespaltenen Serien, d. h. die Anzahl an Differenzierungen zur Herstellung von Stationarität
- q = Anzahl an gleitenden Fehler-Mittelwerten

Ein ARIMA-Modell lässt sich allgemein durch die nachfolgende Gleichung beschreiben⁶³:

$$\hat{y}_t = c + \left[\sum_{i=1}^p \alpha_i \cdot y_{t-i} \right] \pm \sum_{j=1}^q \beta_j \cdot \varepsilon_{t-j}$$

mit \hat{y}_t Prognosewert zum Zeitpunkt t

⁵⁹ Vgl. Yule, G. U. (1926): Why do We Sometimes get Nonsense-Correlations between Time-Series? A Study in Sampling and the Nature of Time-Series. In: Journal of Royal Statistical Society, 89 (1926) 1, S. 1-63., Wold, H.O.A. (1938). A study in the analysis of stationary time series. Stockholm: Almqvist & Wiksell.

⁶⁰ Vgl. Box, G. E. P., Jenkins, G. M. (1970): Time Series Analysis: Forecasting and Control. 1970. San Francisco: Holden Day.

⁶¹ Vgl. Whittle, P. (1951): Hypothesis Testing in Time Series Analysis. 1951. Uppsala: Almqvist & Wiksells.

⁶² Vgl. Carlberg, C. (2013): Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que. (2013: 242).

⁶³ Vgl. Hansmann, K.-W. (1983): Kurzlehrbuch Prognoseverfahren. 1983. Wiesbaden: Gabler. (1983: 65), Hyndman, R. J., Athanasopoulos, G. (2014): Forecasting: Principles and Practice. 2014. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp>. (2014: 223), Vogel, J. (2015): Prognose von Zeitreihen: Eine Einführung für Wirtschaftswissenschaftler. 2015. Wiesbaden: Springer Gabler. (2015: 80). Der Konvention von Box/Jenkins folgend wird der MA-Term subtrahiert. Einige Autoren sowie Softwaresysteme und Scriptsprachen (z. B. R) definieren den MA-Term jedoch mit einem positiven Vorzeichen.

- y_{t-i} Differenzierter Beobachtungswert zum Zeitpunkt $t - i$;
- y_t lässt sich als d^{th} Differenz der Beobachtungswerte y_t^b definieren, mit
- $d = 0$: $y_t = y_t^b$
- $d = 1$: $y_t = y_t^b - y_{t-1}^b$
- $d = 2$: $y_t = (y_t^b - y_{t-1}^b) - (y_{t-1}^b - y_{t-2}^b) = y_t^b - 2 \cdot y_{t-1}^b + y_{t-2}^b$
- usw.
- c Konstante
- α_i AR-Koeffizient des Lags i (y_{t-i}) mit $-1 < \alpha_i < 1$ (diese Beschränkung folgt aus der Stationarität), wobei gilt: $\sum_{i=1}^p \alpha_i \neq 1$
- β_j MA-Koeffizient des Lags j bzw. des vergangenen Schätzfehlers zum Zeitpunkt $t - j$
- ε_{t-j} Schätzfehler (weißes Rauschen, white noise) zum Zeitpunkt $t - j$, mit $\varepsilon_{t-j} = \hat{y}_{t-j} - y_{t-j}$

Neben exponentiellen Glättungen kommen ARIMA-Modelle bei Zeitreihenanalysen am häufigsten zum Einsatz.⁶⁴ Während exponentielle Glättungen dazu verwendet werden, Trends und saisonale Muster zu beschreiben, dienen ARIMA-Modelle der Beschreibung von Autokorrelationen.⁶⁵

5.6.1 AR-Modell

Das **AR-Modell**, also das autoregressive Teilmodell, beruht auf der Annahme, dass Teile der Zeitreihe durch ein lineares Modell beschreibbar sind. *Autoregression* bedeutet, dass ein Wert einer Zeitreihe zum Zeitpunkt t , abgesehen von Zufällen, eine Linearkombination von Werten vorhergehender Zeitpunkte ist.⁶⁶ Der Term *Autoregression* weist darauf hin, dass es sich um eine Regression einer Größe (y) gegen sich selbst handelt.⁶⁷ Gleiches gilt für eine *Autokorrelation*, auch Kreuzkorrelation genannt, die die Korrelation einer Größe mit sich selbst zu einem früheren Zeitpunkt beschreibt. Autokorrelationen wie

⁶⁴ Vgl. Carlberg, C. (2013): Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que (2013: 241), Hyndman, R. J., Athanasopoulos, G. (2014): Forecasting: Principles and Practice. 2014. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp> (2014: 213).

⁶⁵ Vgl. Hyndman, R. J., Athanasopoulos, G. (2014): Forecasting: Principles and Practice. 2014. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp> (2014: 213).

⁶⁶ Vgl. Hyndman, R. J., Athanasopoulos, G. (2014): Forecasting: Principles and Practice. 2014. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp> (2014: 223), Vogel, J. (2015): Prognose von Zeitreihen: Eine Einführung für Wirtschaftswissenschaftler. 2015. Wiesbaden: Springer Gabler. (2015: 79).

⁶⁷ Vgl. Hyndman, R. J., Athanasopoulos, G. (2014): Forecasting: Principles and Practice. 2014. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp> (2014: 223).

auch Korrelationen können in Form einer sogenannten Scheinkorrelation (siehe Kapitel 2) ein Problem beinhalten.⁶⁸

Um nun sinnvoll autoregressive Vorhersagen treffen zu können, muss ein etwaiger Trend in der Zeitreihe eben aufgrund des potenziellen Problems einer Scheinkorrelation durch Herstellung von Stationarität mittels Differenzierung beseitigt werden. Wie bereits in Kapitel 2 erwähnt, wird der Begriff der Stationarität in der Statistik zur Beschreibung einer Situation gebraucht, bei der Verteilungsparameter (wie der Mittelwert bzw. Erwartungswert) und die Varianz zeitunabhängig sind. Nimmt beispielsweise der Mittelwert oder die Varianz einer Zeitreihe zu, so ist die durch einen funktionalen Zusammenhang beschriebene Zeitreihe nicht stationär. Im Falle eines zunehmenden Mittelwerts können unter Umständen sinnvolle Vorhersagen mit dem ARIMA-Modell getätigt werden, im Falle zunehmender Varianzen ist dies nicht mehr möglich.

Der erste Teil der obigen Gleichung ist die allgemeine Form der Beschreibung von $AR(p)$ -Modellen. Der Name autoregressiv wird gewählt, weil dieser Term einer Regressionsgleichung ähnlich ist.⁶⁹ Die Prädiktoren des AR-Modells sind die zeitverschobenen Variablen.⁷⁰

Die Bestimmung der Ordnung p erfolgt über einen iterativen (schrittweisen) Prozess.⁷¹ Dabei lassen sich sowohl Regressions- als auch Korrelationsanalysen verwenden.

Man beginnt annahmegemäß bei $p = 1$ und prüft, ob der Koeffizient $\alpha_1 \neq 0$ ist. Ist dies der Fall, wird die Prüfung für $p = 2$ fortgesetzt usw. Gilt für ein bestimmtes p die Bedingung $\alpha_p = 0$, so ist der AR-Prozess $(p-1)$ -ter Ordnung. Ist beispielsweise für $p = 1$ der Koeffizient $\alpha_1 = 0$, so ist der AR-Prozess null-ter Ordnung. Zur Bestimmung der Koeffizienten lassen sich Regressionsanalysen verwenden. Über den Signifikanzwert⁷² kann dann bestimmt werden, ob ein signifikanter Zusammenhang zwischen der ersten und zweiten Zeitreihe (beide Zeitreihen sind um eine Periode versetzt). Im nächsten Schritt lässt sich eine Regression mit drei Zeitreihen vornehmen, wobei die Zeitreihen jeweils um eine Periode versetzt sind. Über den p -Wert kann dann wiederum bestimmt werden, ob ein signifikanter Zusammenhang zwischen den drei Zeitreihen besteht.

⁶⁸ Vgl. Carlberg, C. (2013): Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que (2013: 241).

⁶⁹ Vgl. Hansmann, K.-W. (1983): Kurzlehrbuch Prognoseverfahren. 1983. Wiesbaden: Gabler.(1983: 65).

⁷⁰ Vgl. Hyndman, R. J., Athanasopoulos, G. (2014): Forecasting: Principles and Practice. 2014. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp> (2014: 223).

⁷¹ Vgl. Hansmann, K.-W. (1983): Kurzlehrbuch Prognoseverfahren. 1983. Wiesbaden: Gabler.(1983: 66 f.).

⁷² Der Signifikanzwert, auch als p -Wert oder p -Value bezeichnet, ist die Wahrscheinlichkeit, dass eine Teststatistik (Prüfgröße; Zusammenfassung der Datenreihe in eine einzelne Größe) einen bloß durch Zufall zustande gekommenen Wert annimmt, der mindestens so gut ist wie ein vorgegebener Wert. Es handelt sich hierbei um die Wahrscheinlichkeit, dass unter der Annahme, die Nullhypothese wahr sei, die Teststatistik mindestens einen vorgegebenen Wert annimmt. Der Signifikanzwert ist also in Form eines Wahrscheinlichkeitswertes ein Maß für den Zufall. Hat eine Teststatistik einen bestimmten Wert (z. B. drei (von 4) richtige erkannt), so muss der Signifikanzwert auch noch all diejenigen Werte der Teststatistik berücksichtigen und abdecken, die in Anbetracht des aktuellen Wertes ebenfalls noch möglich wären (z. B. den Wert für 4). Die Wahrscheinlichkeitsangabe für nur den einen Wert reicht eben nicht aus, um dem Zufall umfassend Tribut zu zollen. Bezieht man alle Wahrscheinlichkeitswerte der noch möglichen Werte der Teststatistik mit ein, so wird dem Zufall komplett Rechnung getragen (z. B. die Teststatistikwerte 1 und 2 gelten als gesichert, bei den Werten 3 und 4 kann auch noch der Zufall im Spiel sein; die Summe der Wahrscheinlichkeiten für 3 und 4 ergeben den Signifikanzwert).

Die Bestimmung des autoregressiven Anteils einer Zeitreihe lässt sich ebenfalls über die Berechnung einer zeitversetzten Korrelation ermitteln.⁷³ In Excel wird die Zeitreihe mehrmals nebeneinander aufgeführt und die Korrelationsfunktion ermittelt den Korrelationswert anhand der beiden Zeitreihen. Die erste Zeitreihe umfasst die Werte y_1 bis y_{T-1} und die zweite Zeitreihe die Werte y_2 bis y_T . Die zeit- bzw. periodenversetzte Zeitreihe wird auch als *Lag* bezeichnet. Eine 'gelagte' Variable [lagged variable] ist eine verzögerte Variable [delayed variable], die ihre Werte aus früheren Perioden derselben Variablen bezieht. Der Wert einer gelagten Variable zum Zeitpunkt t entspricht dem Wert derselben Variable zu einem früheren Zeitpunkt $t - l$. Der Grad l des Lags entspricht der Anzahl der zurückliegenden Perioden ($t - l$) zur Bestimmung des Werts der gelagten Variablen zum Zeitpunkt t . Die Korrelation zwischen einer Zeitreihe und um eine Periode versetzte Zeitreihe wird auch als eine um eine Periode verzögerte Autokorrelation oder *Lag 1 Autocorrelation* bezeichnet.⁷⁴ Je nach Zeit- bzw. Periodenversatz spricht man von Lag 2 Autokorrelation, Lag 3 Autokorrelationen usw.⁷⁵ Die zu korrelierenden Zeitreihen wären demnach bei:

- Lag 1: y_1 bis y_{T-1} und y_2 bis y_T
- Lag 2: y_1 bis y_{T-2} und y_3 bis y_T
- Lag 3: y_1 bis y_{T-3} und y_4 bis y_T

Allgemein sind die zu korrelierenden Zeitreihen für eine Lag l Autokorrelation:

y_1 bis y_{T-l} und y_{l+1} bis y_T

Im Rahmen der Bestimmung der Ordnung p eines AR-Modells müssen Lag 1, Lag 2, Lag 3 Autokorrelationen usw. vorgenommen werden. Weisen nun die zu korrelierenden Zeitreihen jeweils einen Trend auf und ist der simple Grund für den Trend der Faktor *Zeit*, dann muss der Trend aus der Zeitreihe eliminiert werden.

5.6.2 MA-Modell

Der zweite Teil der obigen Gleichung ist die allgemeine Form der Beschreibung eines MA(q)-Modells, das sich über vergangene Schätzfehler definiert.⁷⁶

5.7 Vektorautoregressive Modelle VAR

Autoregressive Modelle wie ARIMAX sind in der Hinsicht limitiert, als dass eine unidirektionale Beziehung vorausgesetzt wird, sprich die abhängige Variable wird von den unabhängigen Variablen beeinflusst, aber nicht andersherum. VAR-Modelle werden verwendet, wenn die dynamischen Beziehungen zwischen mehreren Zeitreihenvariablen modelliert werden sollen. In einem VAR-Modell

⁷³ Vgl. Carlberg, C. (2013): Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que Carlberg (2013: 134 ff. u. 244 ff.).

⁷⁴ Vgl. Carlberg, C. (2013): Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que (2013: 134).

⁷⁵ Vgl. Carlberg, C. (2013): Predictive Analytics: Microsoft Excel. 2013. Indianapolis, Indiana: Que (2013: 135).

⁷⁶ Vgl. Hansmann (1983: 69 ff.), Hyndman, R. J., Athanasopoulos, G. (2014): Forecasting: Principles and Practice. 2014. OTexts. Zugriff unter: <https://www.otexts.org/book/fpp> (2014: 224).

wird jede Variable als eine Funktion ihrer eigenen verzögerten Werte und der verzögerten Werte der anderen Variablen im System modelliert. VAR-Modelle sind besonders nützlich, wenn die Variablen voneinander abhängig sind und wenn die Dynamik des Systems komplex und mit traditionellen statistischen Methoden schwer zu modellieren ist.

Die allgemeine Form eines VAR-Modells für p Variablen, jeweils mit T Beobachtungen, lautet:

$$y_t = v + A_1 \cdot y_{t-1} + A_2 \cdot y_{t-2} + u_t$$

wobei y_t ein $k \times 1$ Vektor endogener Variablen zum Zeitpunkt t ist, v ist ein $k \times 1$ Vektor mit Konstanten, A_i ist eine $k \times k$ Matrix von Koeffizienten für das i -te lag von y_t , u_t ist ein $k \times 1$ Vektor von Fehlertermen zum Zeitpunkt t und p ist die Ordnung des VAR-Modells. Zur Verdeutlichung hier ein 2-dimensionales VAR-System mit den Variablen x_t und y_t zum Zeitpunkt t , wodurch das VAR(1)-Modell wie folgt geschrieben werden kann:

$$x_t = v_1 + A_{11} \cdot x_{t-1} + A_{12} \cdot y_{t-1} + u_{1,t}$$

$$y_t = v_2 + A_{21} \cdot x_{t-1} + A_{22} \cdot y_{t-1} + u_{2,t}$$

v_1 und v_2 als Konstanten, die die Achsenabschnitte der Gleichungen darstellen, A_{11} A_{12} A_{21} A_{22} als Koeffizienten, die den Einfluss der verzögerten Werte der Variablen auf die aktuellen Werte messen, sowie $u_{1,t}$ $u_{2,t}$ die Fehlerterme, welche die zufällige und unvorhersehbare Komponente der Variablen erfassen.

6 Modellauswahl und Ergebnisse

In diesem Abschnitt wird die methodische Vorgehensweise zur Erstellung und zum Vergleich einer Vielzahl von Modellen für die Prognose des Lastenergieverbrauchs in dezentralen Strukturen detailliert beschrieben. Das übergeordnete Ziel besteht darin, das am besten geeignete Modell zu identifizieren, welches in der Lage ist, eine effiziente Vorhersage des Lastenergieverbrauchs in verschiedenen Netzwerktypen innerhalb dezentraler Strukturen zu liefern.

Die ersten Schritte umfassen die Sammlung und Bereinigung von Laststromdaten aus verschiedenen Netzwerken. Dies beinhaltet die Handhabung mit fehlenden Werten und Unstimmigkeiten durch geeignete Imputationsverfahren und Datenbereinigungsverfahren. Zusätzlich werden Wetter- und Kalenderdaten als ergänzende Merkmale integriert, um relevante Kontextinformationen zu erfassen und in die Analyse einzubeziehen.

Die aufbereiteten Daten werden in Trainings-, Validierungs- und Testgruppen aufgeteilt. Hierbei wird ein zeitbasierter Ansatz verwendet, um sicherzustellen, dass jede Gruppe verschiedene Zeiträume repräsentiert und ein vielfältiges Spektrum an Lastenergiemustern enthält.

Die Architektur jedes Modells wird mit großer Sorgfalt entwickelt, um die einzigartigen Merkmale und zeitlichen Abhängigkeiten der Lastenergie-Daten bestmöglich zu erfassen. Im nächsten Abschnitt werden die spezifischen architektonischen Konfigurationen für jedes Modell im Detail erläutert.

6.1 Modelle

6.1.1 Long Short-Term Memory Modell (LSTM)

Das LSTM-Modell beinhaltet LSTM-Schichten, die spezialisierte rekurrente Schichten sind, welche in der Lage sind, langfristige Abhängigkeiten in Zeitreihendaten zu erfassen.⁷⁷ Die LSTM-Gleichungen können wie folgt dargestellt werden:

$$\begin{aligned}
 f_t &= \sigma(W_f x_t + U_f h_{t-1} + b_f) \\
 i_t &= \sigma(W_j x_t + U_o h_{t-1} + b_o) \\
 o_t &= \sigma(W_o x_t + U_o h_{t-1} + b_o) \\
 c_t &= f_t \odot c_{t-1} + i_t \odot \tanh(W_c x_t + U_c h_{t-1} + b_c) \\
 h_t &= o_t \odot \tanh(c_t)
 \end{aligned}$$

wobei x_t die Eingabe zum Zeitpunkt t , h_t die Ausgabe zum Zeitpunkt t , W und U Gewichtsmatrizen, b der Bias-Vektor und σ die Sigmoid-Aktivierungsfunktion sind.⁷⁸ In der nachfolgenden Abbildung und Tabelle können die Architektur und die Eingabeparameter entnommen werden:

⁷⁷ Vgl. Song, X., Liu, Y., Xue, L., Wang, J., Zhang, J., Wang, J., Jiang, L., & Cheng, Z. (2020). Time-series well performance prediction based on long short-term memory (lstm) neural network model. *Journal of Petroleum Science and Engineering*, 186, 106682. <https://doi.org/10.1016/j.petrol.2019.106682>

⁷⁸ Vgl. Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*, 31(7), 1235–1270. https://doi.org/10.1162/neco_a_01199

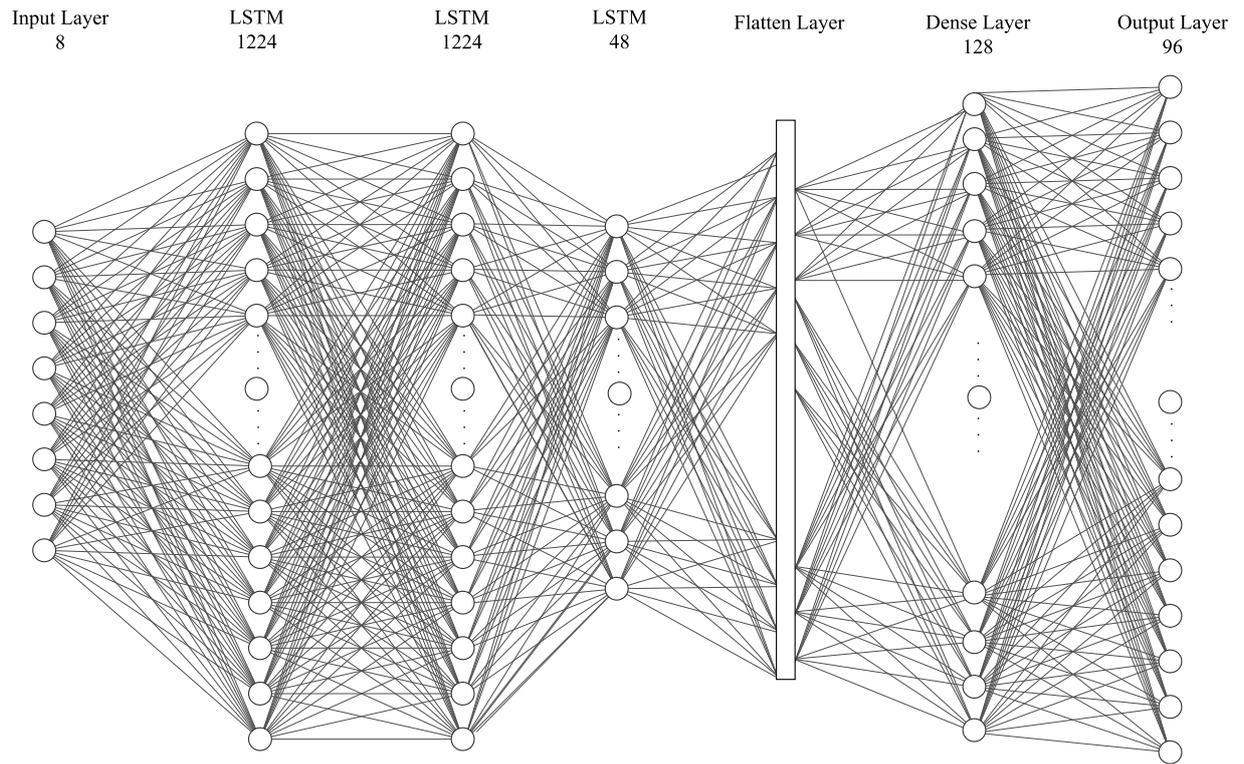


Abbildung 9: LSTM-Architektur

6.1.2 Bidirectional LSTM Modell (BiLSTM)

Das BiLSTM-Modell⁷⁹ umfasst sowohl vorwärts als auch rückwärts gerichtete LSTM-Schichten. Die Vorwärts-LSTM-Gleichungen ähneln den oben genannten Gleichungen, und die Rückwärts-LSTM-Gleichungen können ähnlich dargestellt werden, jedoch mit einem umgekehrten Zeitindex. In der nachfolgenden Abbildung kann die Architektur und die Eingabeparameter entnommen werden.

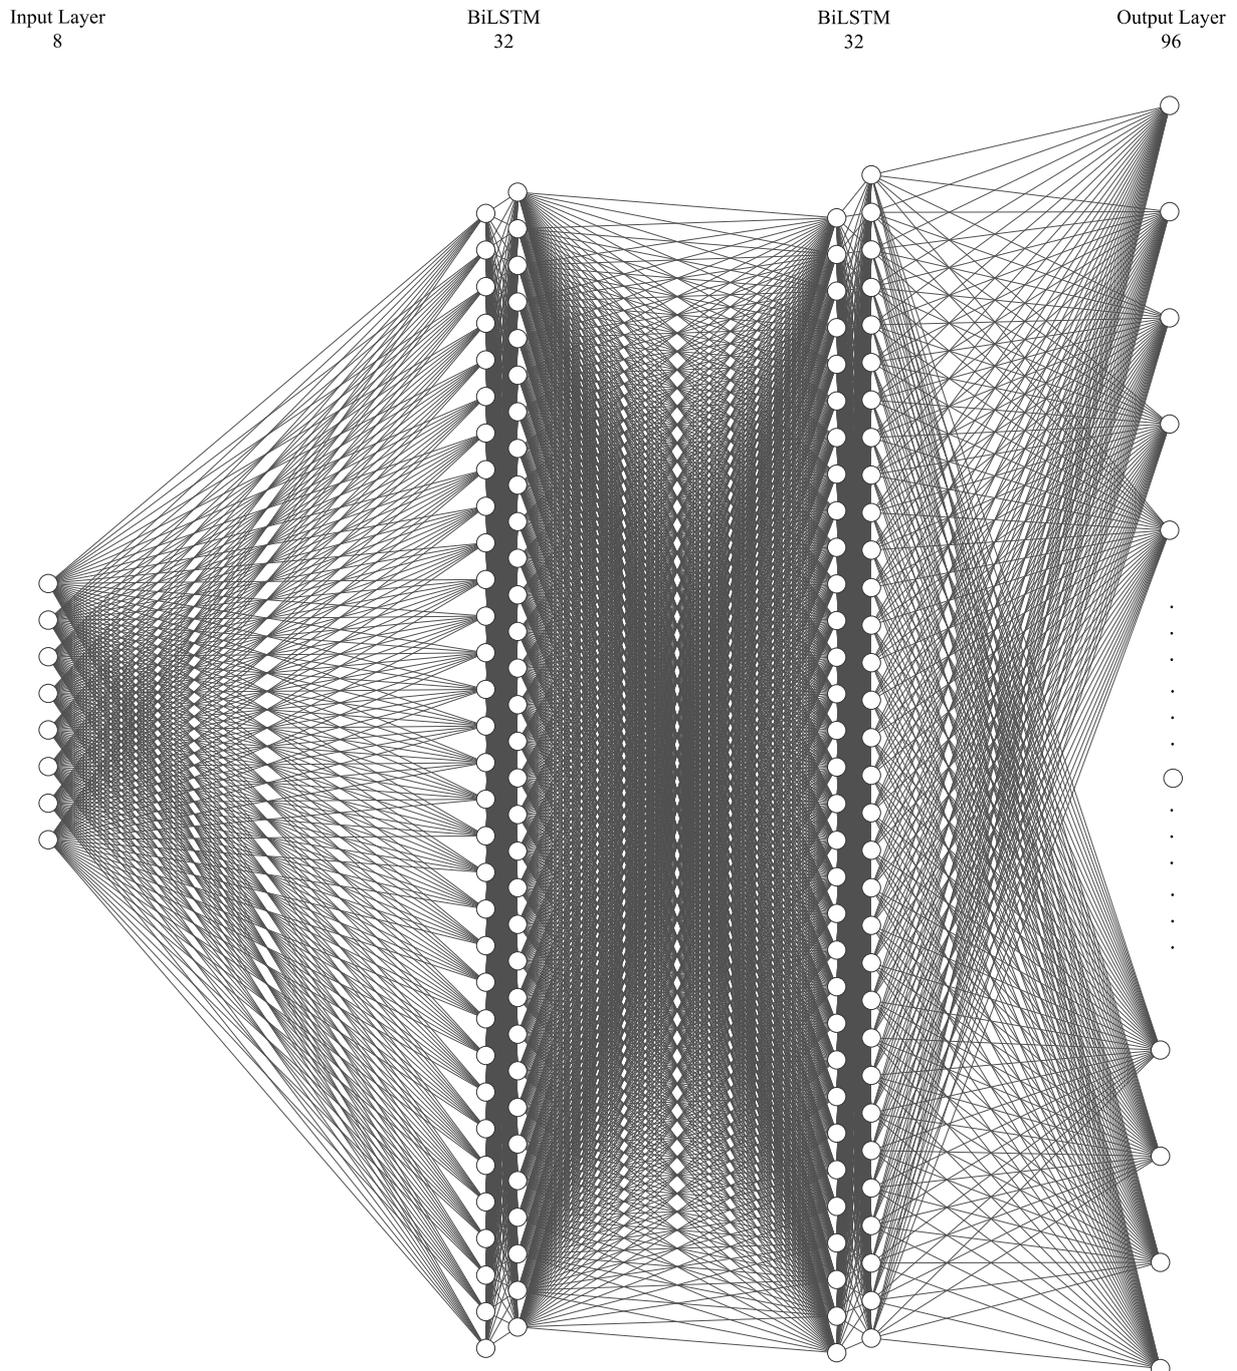


Abbildung 10: BiLSTM Architektur

⁷⁹ Vgl. Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2019). The performance of lstm and bilstm in forecasting time series. *2019 IEEE International Conference on Big Data (Big Data)*, 3285–3292. <https://doi.org/10.1109/BigData47090.2019.9005997>

6.1.3 Convolutional Neuronales Network (CNN):

Das CNN-Modell wird für 1D-Zeitreihendaten mit 1D-Faltungsschichten angepasst.⁸⁰ Die Faltungsoperation kann wie folgt dargestellt werden:

$$y_i = \sigma\left(\sum_{j=1}^m W_j x_{i+j-1} + b\right)$$

Wobei y_i die Ausgabe an der Position i , W_j die Filtergewichte, x_{i+j-1} die Eingabewerte und σ die Aktivierungsfunktion sind. In der nachfolgenden Abbildung kann die Architektur und die Eingabeparameter entnommen werden:

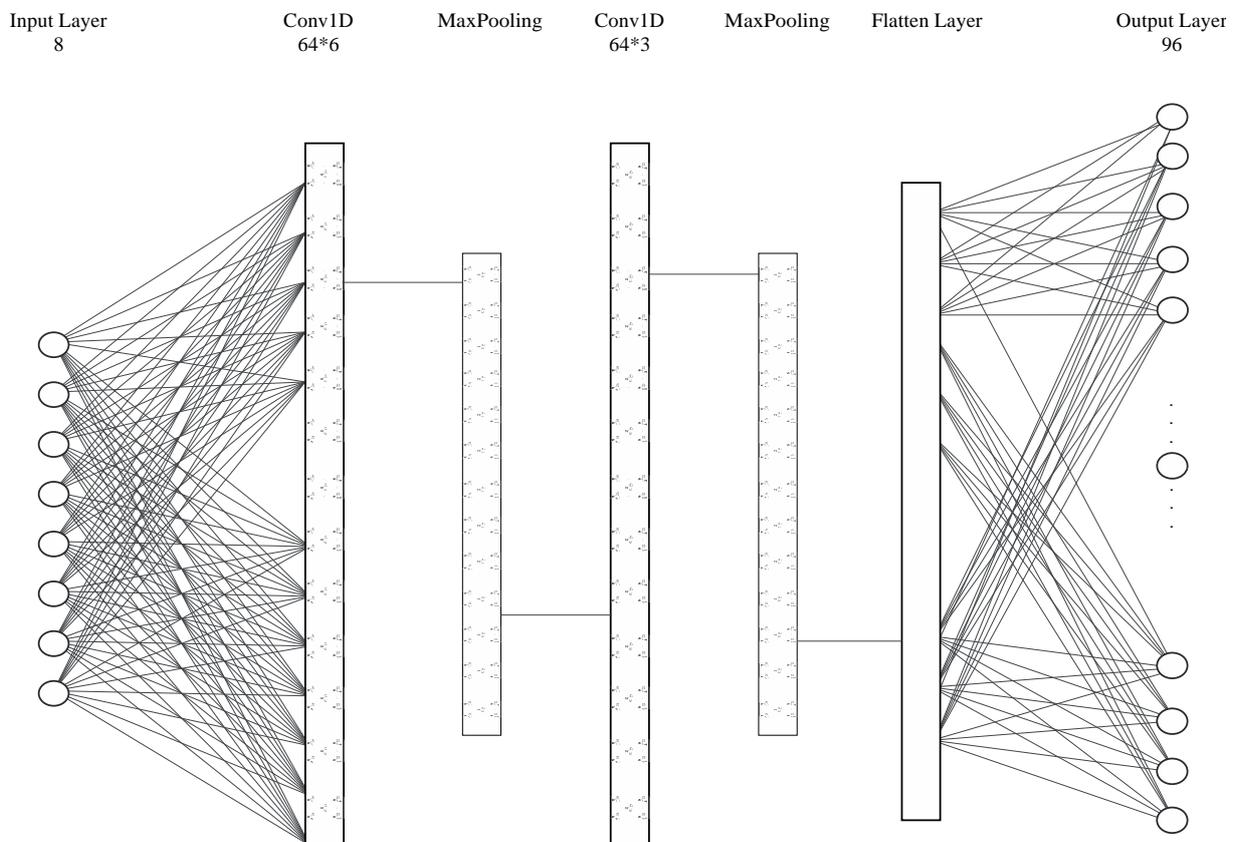


Abbildung 11: CNN-Architektur

CNN-BiLSTM-Modell

⁸⁰ Vgl. Li, L., Ota, K., & Dong, M. (2017). Everything is image: Cnn-based short-term electrical load forecasting for smart grid. *2017 14th International Symposium on Pervasive Systems, Algorithms and Networks & 2017 11th International Conference on Frontier of Computer Science and Technology & 2017 Third International Symposium of Creative Computing (ISPAN-FCST-ISCC)*, 344–351. <https://doi.org/10.1109/ISPAN-FCST-ISCC.2017.78>

Das CNN-BiLSTM-Modell kombiniert CNN-Schichten mit BiLSTM-Schichten, um sowohl lokale Muster als auch langfristige Abhängigkeiten zu erfassen.⁸¹

Convolutional LSTM (ConvLSTM) Modell:

Das ConvLSTM-Modell⁸² integriert Faltungsschichten in LSTM-Zellen, um gleichzeitig räumliche und zeitliche Abhängigkeiten zu erfassen.

6.1.4 VGG-Architektur, Inception Insep-Architektur, Inception Insp-LSTM-Architektur und Xception-Architektur

Diese Modelle⁸³ folgen ihren jeweiligen architektonischen Designs und Gleichungen, wie sie in der Literatur vorgeschlagen werden.

In der nachfolgenden Abbildung und Tabelle können die Architektur und die Eingabeparameter für das VGG entnommen werden:

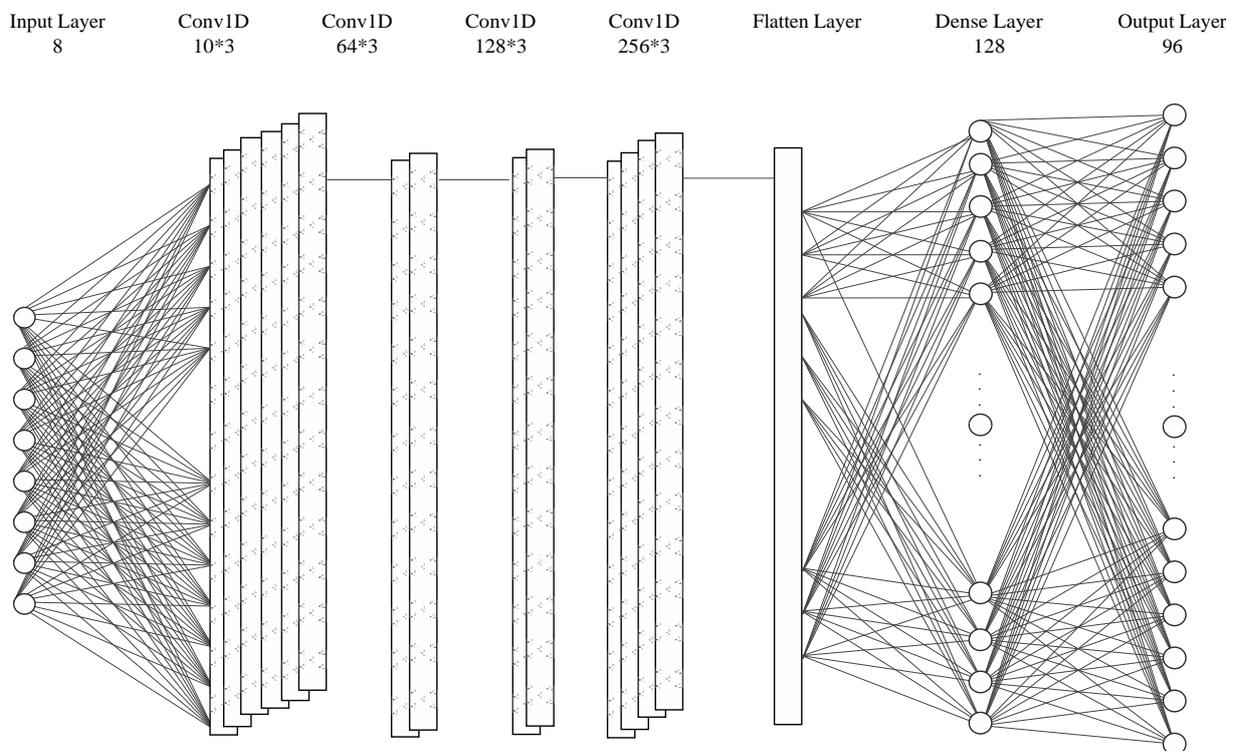


Abbildung 12 VGG-Architektur

⁸¹ Vgl. Chen, Y., & Fu, Z. (2023). Multi-step ahead forecasting of the energy consumed by the residential and commercial sectors in the united states based on a hybrid cnn-bilstm model. *Sustainability*, 15(3). <https://doi.org/10.3390/su15031895>

⁸² Vgl. Khan, N., Haq, I. U., Ullah, F. U. M., Khan, S. U., & Lee, M. Y. (2021). CI-net: Convlstm- based hybrid architecture for batteries’s state of health and power consumption forecasting. *Mathematics*, 9(24). <https://doi.org/10.3390/math9243326>

⁸³ Vgl. Sadaei, H. J., de Lima e Silva, P. C., Guimarães, F. G., & Lee, M. H. (2019). Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series. *Energy*, 175, 365–377. <https://doi.org/https://doi.org/10.1016/j.energy.2019.03.081>

6.1.5 Inception-Insep-Architektur

Die Inception-Insep-Architektur verwendet Inception-Module mit trennbaren Faltungen. Diese Architektur erfasst effizient mehrskalige Merkmale und kann für Last-Energie-Prognosen in dezentralen Strukturen angepasst werden.

6.1.6 Inception Insp-LSTM-Architektur

Die Inception Insp-LSTM-Architektur kombiniert inception -Module mit LSTM-Schichten. Dadurch kann das Modell sowohl räumliche Abhängigkeiten durch die Inception-Module als auch zeitliche Abhängigkeiten durch die LSTM-Schichten erfassen.

6.1.7 VGG-LSTM-Architektur

Die VGG-LSTM-Architektur kombiniert die VGG-Module (*Visual Geometry Group*) mit LSTM-Schichten, um sowohl räumliche als auch zeitliche Abhängigkeiten zu erfassen. Die VGG-Architektur wurde ursprünglich für Bilderkennungsaufgaben entwickelt, kann aber im Kontext der Laststromprognose an die Verarbeitung von Zeitreihendaten angepasst werden. Die VGG-Module bestehen aus mehreren Faltungsschichten mit kleinen Filtern und Maxpooling-Schichten, die zur Erfassung hierarchischer Merkmale auf verschiedenen Skalen beitragen. Diese Faltungsschichten können effizient lokale Muster aus den Zeitreihendaten extrahieren.

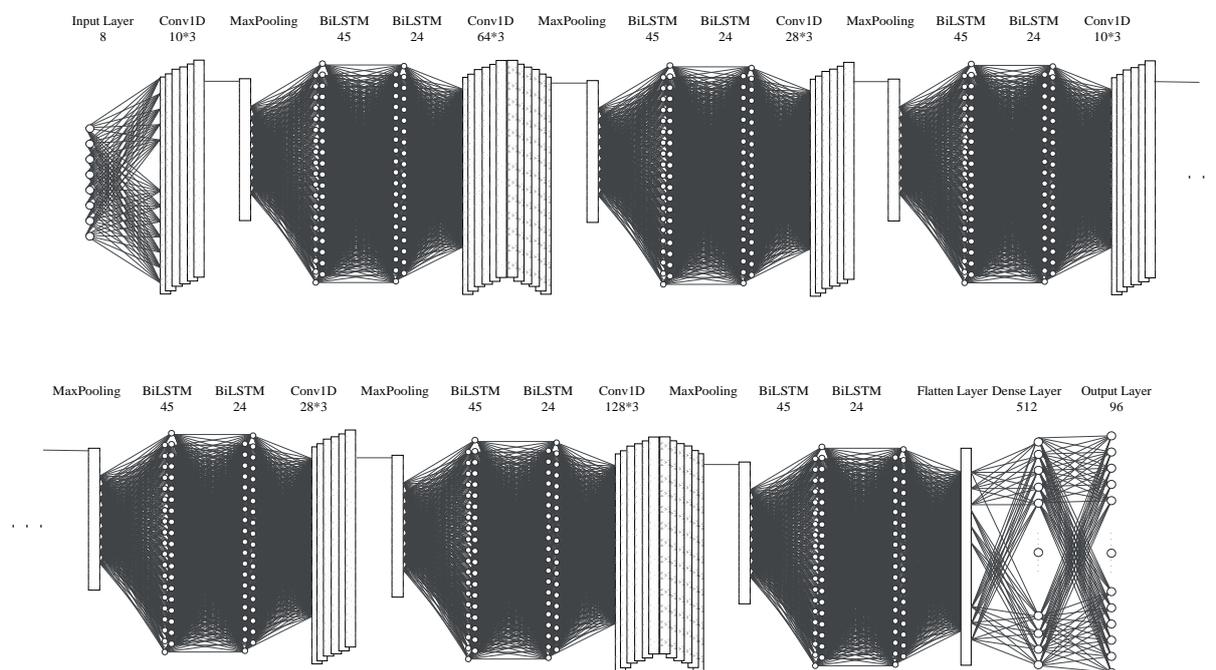


Abbildung 13 VGG-LSTM-Architektur

6.1.8 Xception-Architektur

Die Xception-Architektur basiert auf separierbaren Faltungen in der Tiefe, welche die Anzahl der Parameter im Vergleich zu herkömmlichen Faltungsschichten erheblich reduzieren. Diese Architektur

stellt ein Gleichgewicht zwischen Modellkomplexität und Leistung her und kann für Last-Energie-Prognosen in dezentralen Strukturen verwendet werden.

6.2 Ergebnisse der Prognosemodelle

In diesem Abschnitt sind die Ergebnisse der Last-Energie-Prognosemodelle und die Analyse ihrer Leistungen dargestellt. Insbesondere steht die Leistung der Modelle ohne und mit Einbeziehung des Netzwerktypmerkmals im Vergleich. Anschließend erfolgt eine Erörterung der Erkenntnisse, die sich aus der Einbeziehung des Netzwerktypmerkmals ergeben.

Model	Metric	D1	D2	D3	D4	D5	D6
CNN	MAE	19.51	20.64	25.89	20.96	23.26	20.86
	MAPE	90.76	97.50	119.86	105.01	95.62	113.70
BiLSTM	MAE	15.25	14.25	14.52	14.80	14.75	14.54
	MAPE	78.72	76.98	78.31	80.88	79.72	81.96
VGG	MAE	10.85	11.20	10.95	11.04	11.08	11.61
	MAPE	65.38	73.55	73.94	75.58	77.32	71.68
Xception	MAE	33.75	16.60	15.04	16.10	14.22	16.22
	MAPE	114.96	104.37	82.88	96.96	87.64	85.13
Inception	MAE	12.15	13.48	13.77	13.81	13.70	13.86
	MAPE	73.78	79.44	80.64	87.11	84.67	83.69
Inception_LSTM	MAE	16.64	16.35	15.36	15.41	15.74	15.63
	MAPE	83.36	78.10	74.92	76.12	78.07	76.07
Xception_LSTM	MAE	27.28	21.72	21.72	22.24	23.30	24.01
	MAPE	155.51	113.78	92.00	87.96	96.36	125.92
VGG_LSTM	MAE	10.68	10.33	10.71	11.24	10.90	10.90
	MAPE	52.44	61.90	59.70	61.27	63.86	63.52

Tabelle 3: Evaluation der Leistung der Modelle ohne Grid Type Feature

Tabelle 8 zeigt die Leistungskennzahlen der Last-Energie-Prognosemodelle ohne das Merkmal (Grid Type) Netzwerktyp in der Testgruppe. Die Metriken umfassen den mittleren absoluten Fehler (MAE) und den mittleren absoluten prozentualen Fehler (MAPE). Aus der Tabelle geht hervor, dass das VGG_LSTM-Modell unter allen Modellen ohne das Grid Type Merkmal am besten abschneidet. Es erreicht die niedrigsten MAE- und MAPE-Werte, was auf eine überragende Leistung bei der Prognose der Lastenergie hinweist.

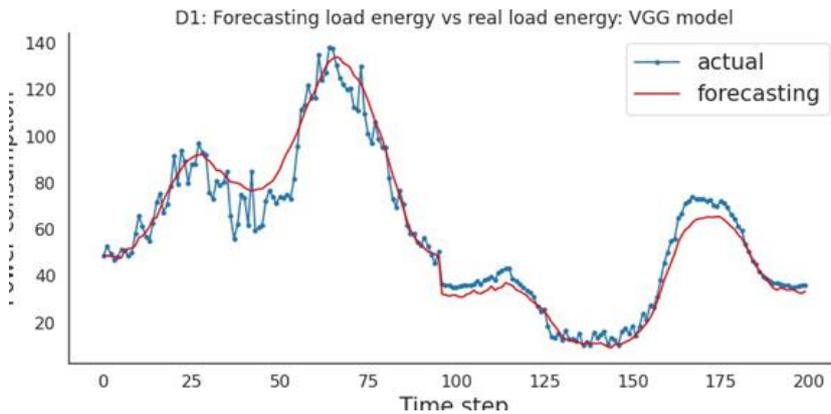


Abbildung 14: Vergleich zwischen tatsächlicher und vorhergesagter Belastung für die Testdaten der durch D1 dargestellten Flächenaktivität.

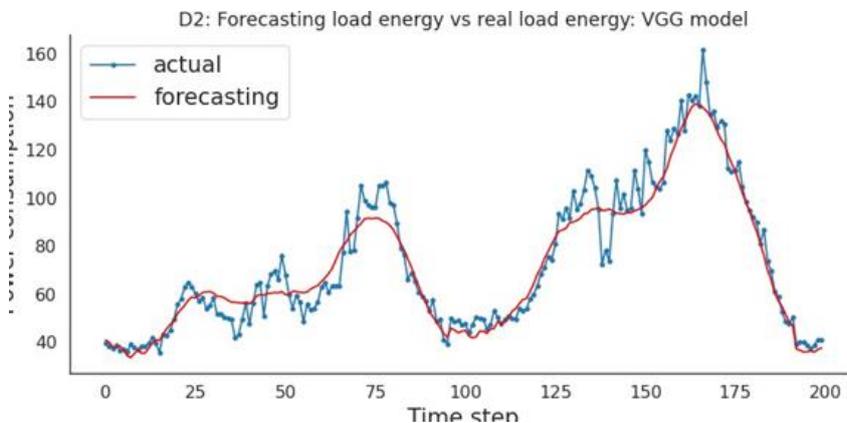


Abbildung 15: Vergleich zwischen tatsächlicher und vorhergesagter Belastung aus den Testdaten der durch D2 dargestellten Flächenaktivität.

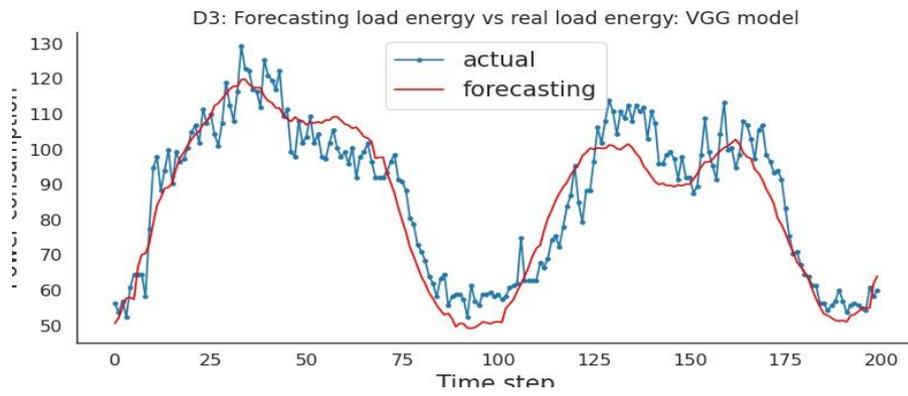


Abbildung 16: Vergleich zwischen tatsächlicher und vorhergesagter Belastung aus den Testdaten der durch D3 dargestellten Flächenaktivität.

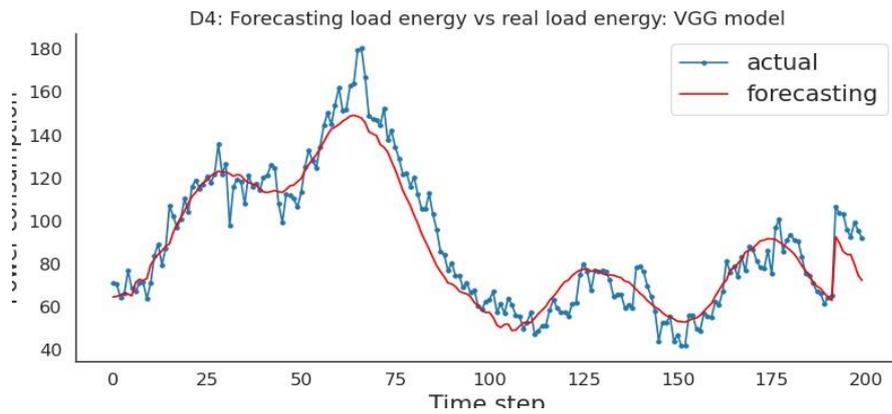


Abbildung 17: Vergleich zwischen tatsächlicher und vorhergesagter Belastung aus den Testdaten der durch D4 dargestellten Flächenaktivität.

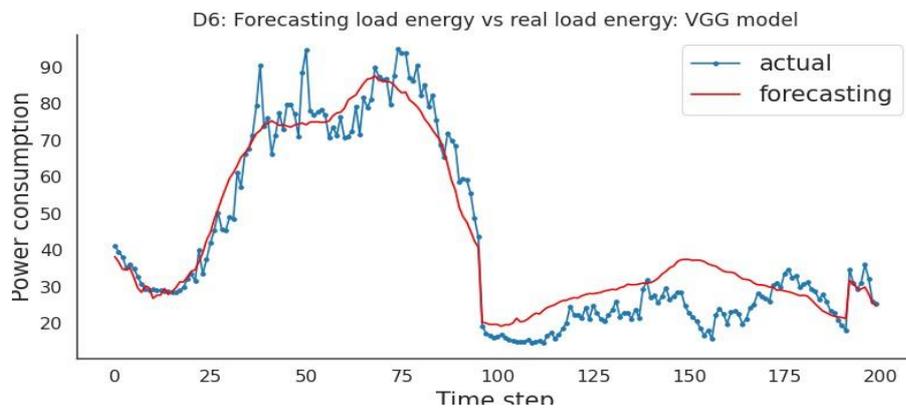
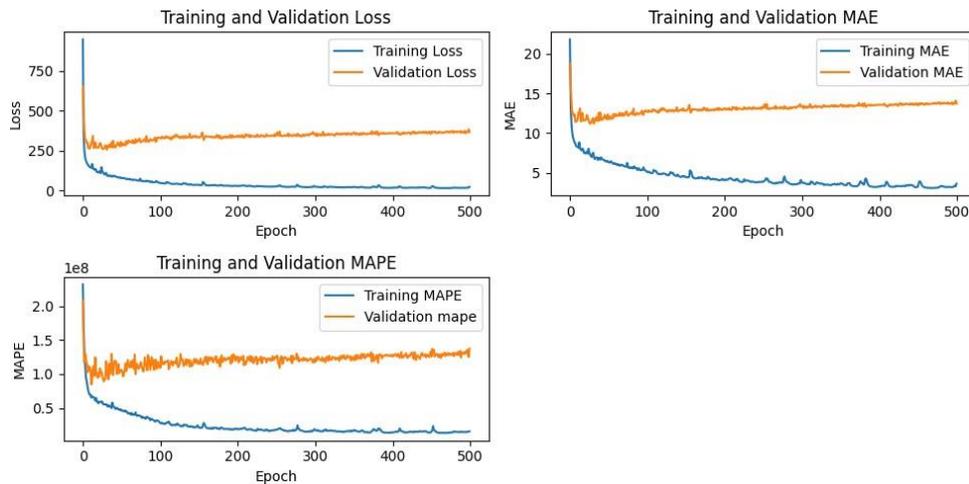
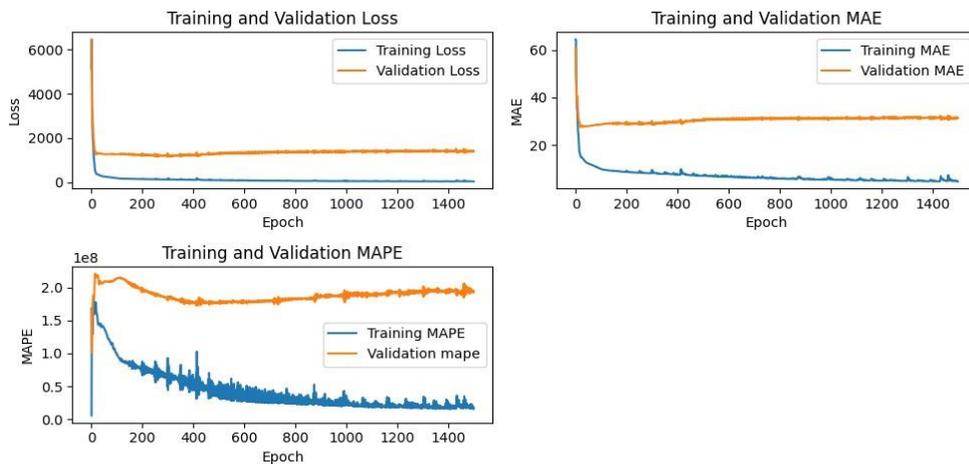


Abbildung 18: Vergleich zwischen tatsächlicher und vorhergesagter Belastung aus den Testdaten der durch D6 dargestellten Flächenaktivität.



Grafik 1: mit Grid Type



Grafik 2: ohne Grid Type

In Grafik 1 und 2 sehen Sie einen Vergleich der Leistung des Systems mit und ohne Grid Type.

Grafik 1 zeigt die Ergebnisse mit Berücksichtigung des Grid Type, während Grafik 2 die Ergebnisse ohne Grid Type zeigt. Dieser Vergleich zeigt deutlich den signifikanten Einfluss des Netzwerktyps auf die Gesamtleistung des Systems. Bei Berücksichtigung des Netzwerktyps sinkt die Ausgangsleistung von 20-40 Kw auf 10-15 Kw.

Im Folgenden werden die gesammelten Erkenntnisse übersichtlich dargestellt:

1. Verbesserung der Genauigkeit: Die Modelle mit dem Grid Type übertreffen die Modelle ohne das Merkmal durchweg in Bezug auf MAE und MAPE. Dies deutet darauf hin, dass das Merkmal Grid Type wertvolle Informationen für die Lastenergie-Prognose liefert und genauere Vorhersagen ermöglicht.
2. Einfluss des Grid Type/Netzwerktyps: Durch die Einbeziehung des Grid Type können die Modelle die Variationen und spezifischen Merkmale der verschiedenen Netzwerktypen

erfassen. Dies verbessert ihre Fähigkeit, sich an die einzigartigen Lastenergie-Muster und Anforderungen der einzelnen Netzwerktypen anzupassen.

3. Modell-Empfehlungen: Unter den Modellen mit dem Netzwerktypmerkmal weist das VGG_LSTM-Modell die beste Leistung auf. Diese Modelle nutzen das Merkmal Grid Type effektiv und erfassen sowohl lokale Muster als auch zeitliche Abhängigkeiten, was zu hochpräzisen Last-Energie-Prognosen führt.

Auf der Grundlage dieser Ergebnisse empfehlen wir die Verwendung des VGG_LSTM-Modells inklusive des Netzwerktypmerkmals für die Vorhersage von Lastenergie in dezentralen Strukturen. Diese Modelle zeigen eine überlegene Leistung und können sich an verschiedene Netztypen innerhalb dezentraler Strukturen anpassen.

7 Fazit

Die in den Abbildungen dargestellten Ergebnisse lassen den Schluss zu, dass das VGG_LSTM-Modell die anderen Ansätze übertrifft und dass sich die Berücksichtigung des Netzwerkmerkmals positiv auf die Gesamtleistung des Systems auswirkt.

In Grafik 1 und 2 wird die Leistung des Systems mit und ohne das Merkmal Grid Type verglichen. Sie zeigt, dass das System bei der Berücksichtigung des Netzwerktypmerkmals (Grafik 1) bessere Ergebnisse erzielt als ohne das Netzwerktypmerkmal (Grafik 2). Dies deutet darauf, dass dem System durch die Information zum Netzwerktyp wertvolle Erkenntnisse geliefert werden, welche zu einer verbesserten Genauigkeit der Lastvorhersage führen.

Die Abbildungen 9, 10, 11, 12 und 13 zeigen die Leistung des VGG_LSTM-Modells für verschiedene Gebiete (D1, D2, D3, D4 und D6). Aus diesen Abbildungen ist ersichtlich, dass das VGG_LSTM-Modell in den verschiedenen Bereichen durchweg gut abschneidet, was auf seine Robustheit und Effektivität bei der Lastenergievorhersage hindeutet.

Unter Berücksichtigung beider Ergebnisse kann man schlussfolgern, dass das VGG_LSTM-Modell ein starker Kandidat für die Lastenergie-Prognose ist und dass die Einbeziehung des Netzwerktypmerkmals diese Leistung weiter steigert. Die Netzwerktypinformation hilft, räumliche Muster und Abhängigkeiten zu erfassen, was zu genaueren Prognosen führt.

Zusammenfassend zeigt die Studie die Überlegenheit des VGG_LSTM-Modells gegenüber anderen Ansätzen und unterstreicht die Bedeutung der Einbeziehung des Netzwerktyps in Lastenergievorhersagemodelle. Die Gründe für dieses Hybridmodells liegen in der Stärke der beiden Netztypen. Während CNNs bzw. VGG sich hervorragend eignen, zyklische Muster aufzudecken sind rekurrente Netze bzw. LSTMs prädestiniert zum Nachvollzug saisonaler Muster. Diese Schlussfolgerung eröffnet potenzielle Anwendungen in verschiedenen Bereichen, in denen genaue Lastenergieprognosen für eine effiziente Ressourcenplanung und -verwaltung entscheidend sind.

- Amral, N., C. S. Ozveren, und D. King. „Short Term Load Forecasting Using Multiple Linear Regression“. In *2007 42nd International Universities Power Engineering Conference*, 1192–98. Brighton, UK: IEEE, 2007. <https://doi.org/10.1109/UPEC.2007.4469121>.
- Antonopoulos, Ioannis, Valentin Robu, Benoit Couraud, Desen Kirli, Sonam Norbu, Aristides Kiprakis, David Flynn, Sergio Elizondo-Gonzalez, und Steve Wattam. „Artificial Intelligence and Machine Learning Approaches to Energy Demand-Side Response: A Systematic Review“. *Renewable and Sustainable Energy Reviews* 130 (September 2020): 109899. <https://doi.org/10.1016/j.rser.2020.109899>.
- Baron-Cohen, S. (1991). Precursors to a theory of mind: Understanding Attention in Others. In Whiten, A (Ed.): *Natural Theories of Mind: Evolution, Development, and Simulation of Everyday Mindreading*. 1991, 233-251. Oxford, UK Cambridge, Massachusetts: B. Blackwell.
- Bashir, Tasarruf, Chen Haoyong, Muhammad Faizan Tahir, und Zhu Liqiang. „Short Term Electricity Load Forecasting Using Hybrid Prophet-LSTM Model Optimized by BPNN“. *Energy Reports* 8 (November 2022): 1678–86. <https://doi.org/10.1016/j.egy.2021.12.067>.
- Bedi, Jatin, und Durga Toshniwal. „Deep Learning Framework to Forecast Electricity Demand“. *Applied Energy* 238 (März 2019): 1312–26. <https://doi.org/10.1016/j.apenergy.2019.01.113>.
- Bouktif, Salah, Ali Fiaz, Ali Ouni, und Mohamed Serhani. „Optimal Deep Learning LSTM Model for Electric Load Forecasting Using Feature Selection and Genetic Algorithm: Comparison with Machine Learning Approaches“. *Energies* 11, Nr. 7 (22. Juni 2018): 1636. <https://doi.org/10.3390/en11071636>.
- Box, George Edward Pelham, Gwilym Meirion Jenkins, Gregory Charles Reinsel, und Greta Marianne Ljung. *Time series analysis: forecasting and control*. John Wiley & Sons, 1970.
- Cai, Mengmeng, Manisa Pipattanasomporn, und Saifur Rahman. „Day-Ahead Building-Level Load Forecasts Using Deep Learning vs. Traditional Time-Series Techniques“. *Applied Energy* 236 (Februar 2019): 1078–88. <https://doi.org/10.1016/j.apenergy.2018.12.042>.
- Carlberg, C. (2013): *Predictive Analytics: Microsoft Excel*. Indianapolis, Indiana: Que.
- Cecati, Carlo, Janusz Kolbusz, Pawel Rozycki, Pierluigi Siano, und Bogdan M. Wilamowski. „A Novel RBF Training Algorithm for Short-Term Electric Load Forecasting and Comparative Studies“. *IEEE Transactions on Industrial Electronics* 62, Nr. 10 (Oktober 2015): 6519–29. <https://doi.org/10.1109/TIE.2015.2424399>.
- Chakhchoukh, Yacine, Patrick Panciatici, und Lamine Mili. „Electric Load Forecasting Based on Statistical Robust Methods“. *IEEE TRANSACTIONS ON POWER SYSTEMS* 26, Nr. 3 (2011).

- Charytoniuk, W., M.S. Chen, und P. Van Olinda. „Nonparametric Regression Based Short-Term Load Forecasting“. *IEEE Transactions on Power Systems* 13, Nr. 3 (August 1998): 725–30. <https://doi.org/10.1109/59.708572>.
- Chen, Ying, Peter B Luh, Che Guan, Yige Zhao, Laurent D Michel, Matthew A Coolbeth, Peter B Friedland, und Stephen J Rourke. „Short-term load forecasting: Similar day-based wavelet neural networks“. *IEEE Transactions on Power Systems* 25, Nr. 1 (2009): 322–30.
- Cheng, Yao, Chang Xu, Daisuke Mashima, Vrizlynn LL Thing, und Yongdong Wu. „PowerLSTM: power demand forecasting using long short-term memory neural network“. In *Advanced Data Mining and Applications: 13th International Conference, ADMA 2017, Singapore, November 5–6, 2017, Proceedings 13*, 727–40. Springer, 2017.
- Chen, Y., & Fu, Z. (2023). Multi-step ahead forecasting of the energy consumed by the residential and commercial sectors in the united states based on a hybrid cnn-bilstm model. *Sustainability*, 15(3). <https://doi.org/10.3390/su15031895>
- Chollet, F. (2018). *Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek*. Deutschland: MITP.
- Christiaanse, W. „Short-Term Load Forecasting Using General Exponential Smoothing“. *IEEE Transactions on Power Apparatus and Systems* PAS-90, Nr. 2 (März 1971): 900–911. <https://doi.org/10.1109/TPAS.1971.293123>.
- Dalal, Gal, Elad Gilboa, und Shie Mannor. „Hierarchical decision making in electricity grid management“. In *International conference on machine learning*, 2197–2206. PMLR, 2016.
- Eid, Cherrelle, Paul Codani, Yannick Perez, Javier Reneses, und Rudi Hakvoort. „Managing Electric Flexibility from Distributed Energy Resources: A Review of Incentives for Market Design“. *Renewable and Sustainable Energy Reviews* 64 (Oktober 2016): 237–47. <https://doi.org/10.1016/j.rser.2016.06.008>.
- Ertel, W. (2016). *Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung*. 4. Aufl., 2016. Wiesbaden: Springer
- Gers, Felix A, Jürgen Schmidhuber, und Fred Cummins. „Learning to forget: Continual prediction with LSTM“. *Neural computation* 12, Nr. 10 (2000): 2451–71.
- Goodfellow, I., Y. Bengio, und A. Courville. *Deep Learning*. Adaptive Computation and Machine Learning series. MIT Press, 2016. <https://books.google.de/books?id=omivDQAAQBAJ>.
- Goodfellow, I. J., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2014): Generative Adversarial Nets. In: *Proceedings of the International Conference on Neural Information Processing Systems (NIPS) 2014*, pp. 2672-2680.

- Graves, Alex, Marcus Liwicki, Santiago Fernández, Roman Bertolami, Horst Bunke, und Jürgen Schmidhuber. „A novel connectionist system for unconstrained handwriting recognition“. *IEEE transactions on pattern analysis and machine intelligence* 31, Nr. 5 (2008): 855–68.
- Graves, Alex, und Jürgen Schmidhuber. „Framewise phoneme classification with bidirectional LSTM and other neural network architectures“. *Neural networks* 18, Nr. 5–6 (2005): 602–10.
- Greene, William H. *Econometric analysis*. Pearson Education India, 2003.
- Han, Lingyi, Yuexing Peng, Yonghui Li, Binbin Yong, Qingguo Zhou, und Lei Shu. „Enhanced Deep Networks for Short-Term and Medium-Term Load Forecasting“. *IEEE Access* 7 (2019): 4045–55. <https://doi.org/10.1109/ACCESS.2018.2888978>.
- Hansmann, K.-W. (1983): Kurzlehrbuch Prognoseverfahren. 1983. Wiesbaden: Gabler. (1983: 65),
- Hastie, Trevor, Robert Tibshirani, und Jerome Friedman. *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*. Second Edition. New York, NY: Springer, 2009.
- Haykin, S.S. *Neural Networks and Learning Machines*. Third Edition. Pearson International Edition. Pearson, 2009.
- Hintze, A. (2016). Understanding the Four Types of Artificial Intelligence. 2016. <https://www.govtech.com/computing/understanding-the-four-types-of-artificial-intelligence.html>.
- Hobbs, Benjamin F, Suradet Jitprapaikularn, Sreenivas Konda, Vira Chankong, Kenneth A Loparo, und Dominic J Maratukulam. „Analysis of the value for unit commitment of improved load forecasts“. *IEEE Transactions on Power Systems* 14, Nr. 4 (1999): 1342–48.
- Hochreiter, Sepp, und Jürgen Schmidhuber. „Long Short-Term Memory“. *Neural Computation* 9, Nr. 8 (1. November 1997): 1735–80. <https://doi.org/10.1162/neco.1997.9.8.1735>.
- Huck, Nicolas. „Pairs selection and outranking: An application to the S&P 100 index“. *European Journal of Operational Research* 196, Nr. 2 (2009): 819–25.
- Hyndman, Rob John, und George Athanasopoulos. *Forecasting: principles and practice*. 2. Aufl. OTexts, 2018.
- International Energy Agency. „Renewables 2022“. Paris, 2022b. <https://www.iea.org/reports/renewables-2022>.
- . „World Energy Outlook 2022“. Paris, 2022a. <https://www.iea.org/reports/world-energy-outlook-2022>.
- Javed, Fahad, Naveed Arshad, Fredrik Wallin, Iana Vassileva, und Erik Dahlquist. „Forecasting for Demand Response in Smart Grids: An Analysis on Use of Anthropologic and Structural Data and Short Term Multiple Loads Forecasting“. *Applied Energy* 96 (August 2012): 150–60. <https://doi.org/10.1016/j.apenergy.2012.02.027>.

- Khan, N., Haq, I. U., Ullah, F. U. M., Khan, S. U., & Lee, M. Y. (2021). CI-net: ConvLstm- based hybrid architecture for batteries's state of health and power consumption forecasting. *Mathematics*, 9(24). <https://doi.org/10.3390/math9243326>
- Khan, Protima, Md Fazlul Kader, SM Riazul Islam, Aisha B Rahman, Md Shahriar Kamal, Masbah Uddin Toha, und Kyung-Sup Kwak. „Machine learning and deep learning approaches for brain disease diagnosis: principles and recent advances“. *IEEE Access* 9 (2021): 37622–55.
- Kohzadi, Nowrouz, Milton S Boyd, Bahman Kermanshahi, und Iebling Kaastra. „A comparison of artificial neural network and time series models for forecasting commodity prices“. *Neurocomputing* 10, Nr. 2 (1996): 169–81.
- Kong, Weicong, Zhao Yang Dong, Youwei Jia, David J. Hill, Yan Xu, und Yuan Zhang. „Short-Term Residential Load Forecasting Based on LSTM Recurrent Neural Network“. *IEEE Transactions on Smart Grid* 10, Nr. 1 (Januar 2019): 841–51. <https://doi.org/10.1109/TSG.2017.2753802>.
- Kriesel, David. *Ein kleiner Überblick über Neuronale Netze*, 2007. <http://www.dkriesel.com>.
- LeCun, Y., Bottou, L., Bengio, Y., Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86 (11), 2278–2324.
- Li, L., Ota, K., & Dong, M. (2017). Everything is image: Cnn-based short-term electrical load forecasting for smart grid. *2017 14th International Symposium on Pervasive Systems, Algorithms and Networks & 2017 11th International Conference on Frontier of Computer Science and Technology & 2017 Third International Symposium of Creative Computing (ISPAN-FCST-ISCC)*, 344–351. <https://doi.org/10.1109/ISPAN-FCST-ISCC.2017.78>
- Liao, Gwo-Ching, und Ta-Peng Tsao. „Application of Fuzzy Neural Networks and Artificial Intelligence for Load Forecasting“. *Electric Power Systems Research* 70, Nr. 3 (August 2004): 237–44. <https://doi.org/10.1016/j.epsr.2003.12.012>.
- Lu, W., Li, J., Li, Y., Sun, A., Wang, J. (2020). A CNN-LSTM-Based Model to Forecast Stock Prices. *Complexity*.
- Lütkepohl, Helmut. *New introduction to multiple time series analysis*. Springer Science & Business Media, 2005.
- Marino, Daniel L., Kasun Amarasinghe, und Milos Manic. „Building Energy Load Forecasting Using Deep Neural Networks“. In *IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society*, 7046–51. Florence, Italy: IEEE, 2016. <https://doi.org/10.1109/IECON.2016.7793413>.
- McCarthy, J. / M. L. Minsky / N. Rochester / C. E. Shannon. A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence. 1955. <http://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>.

- Meier, Jan-Hendrik, Stephan Schneider, Holm Voss, und Anna-Katharina Dhungel. „KI-basiertes Forecasting und Microforecasting von Energieerzeugung und -verbrauch in dezentralen Strukturen“. In *Forschungsberichte zum Energiesystem X.0: Nr. 1: Intelligente und effiziente Vernetzung von Energieerzeugern und -verbrauchern auf Quartiersebene*, herausgegeben von Gesellschaft für Energie und Klimaschutz Schleswig-Holstein GmbH, 154–74. Studienreihe und Ergebnisbericht NEW 4.0, 2021.
- Mitchell, Tom Michael. *Machine learning*. Bd. 1. 9. McGraw-Hill New York, 1997.
- Park, D.C., M.A. El-Sharkawi, R.J. Marks, L.E. Atlas, und M.J. Damborg. „Electric Load Forecasting Using an Artificial Neural Network“. *IEEE Transactions on Power Systems* 6, Nr. 2 (Mai 1991): 442–49. <https://doi.org/10.1109/59.76685>.
- Raza, Muhammad Qamar, und Abbas Khosravi. „A Review on Artificial Intelligence Based Load Demand Forecasting Techniques for Smart Grid and Buildings“. *Renewable and Sustainable Energy Reviews* 50 (Oktober 2015): 1352–72. <https://doi.org/10.1016/j.rser.2015.04.065>.
- Russell, S. J., & Norvig, P. (2021): *Artificial Intelligence: A Modern Approach*. 4rd ed., 2021. Hoboken: Pearson Education.
- Saber, Ahmed Yousuf, und A K M Rezaul Alam. „Short Term Load Forecasting Using Multiple Linear Regression for Big Data“. In *2017 IEEE Symposium Series on Computational Intelligence (SSCI)*, 1–6. Honolulu, HI: IEEE, 2017. <https://doi.org/10.1109/SSCI.2017.8285261>.
- Sadaei, H. J., de Lima e Silva, P. C., Guimarães, F. G., & Lee, M. H. (2019). Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series. *Energy*, 175, 365–377. <https://doi.org/10.1016/j.energy.2019.03.081>
- Schneider, S., Loza, I., (2023). Einführung und Übersicht zu KI. In: T. Hochscherf, & M. Lätzel: *KI und Kultur - Chimäre oder Chance*. 2023.
- Schmidhuber, J. (2015). Deep Learning in Neural Networks: An Overview. In: *Neural Networks*, 61 (2015), 85-117
- Sehovac, Ljubisa, und Katarina Grolinger. „Deep Learning for Load Forecasting: Sequence to Sequence Recurrent Neural Networks With Attention“. *IEEE Access* 8 (2020): 36411–26. <https://doi.org/10.1109/ACCESS.2020.2975738>.
- Shabbir, Noman, Roya Ahmadiyahangar, Lauri Kutt, und Argo Rosin. „Comparison of Machine Learning Based Methods for Residential Load Forecasting“. In *2019 Electric Power Quality and Supply Reliability Conference (PQ) & 2019 Symposium on Electrical Engineering and Mechatronics (SEEM)*, 1–4. Kärddla, Estonia: IEEE, 2019. <https://doi.org/10.1109/PQ.2019.8818267>.

- Shen, Zhixi, Xiaoqin Wu, Josep M Guerrero, und Yongduan Song. „Model-independent approach for short-term electric load forecasting with guaranteed error convergence“. *IET Control Theory & Applications* 10, Nr. 12 (2016): 1365–73.
- Shi, Heng, Minghao Xu, und Ran Li. „Deep Learning for Household Load Forecasting—A Novel Pooling Deep RNN“. *IEEE Transactions on Smart Grid* 9, Nr. 5 (September 2018): 5271–80. <https://doi.org/10.1109/TSG.2017.2686012>.
- Siami-Namini, S., Tavakoli, N., & Namin, A. S. (2019). The performance of lstm and bilstm in forecasting time series. *2019 IEEE International Conference on Big Data (Big Data)*, 3285–3292. <https://doi.org/10.1109/BigData47090.2019.9005997>
- Sun, Wei, und Yi Liang. „Research of Least Squares Support Vector Regression Based on Differential Evolution Algorithm in Short-Term Load Forecasting Model“. *J. Renewable Sustainable Energy*, 2014.
- Sternberg, R. J., & Salter, W. (1982): Conceptions of intelligence. In: Sternberg, R. J. (Ed.): *Handbook of Human Intelligence*. 1982, 3-121. Cambridge: Cambridge University Press.
- Song, X., Liu, Y., Xue, L., Wang, J., Zhang, J., Wang, J., Jiang, L., & Cheng, Z. (2020). Time-series well performance prediction based on long short-term memory (lstm) neural network model. *Journal of Petroleum Science and Engineering*, 186, 106682. <https://doi.org/https://doi.org/10.1016/j.petrol.2019.106682>
- Tarwani, Kanchan M, und Swathi Edem. „Survey on recurrent neural network in natural language processing“. *Int. J. Eng. Trends Technol* 48, Nr. 6 (2017): 301–4.
- Vogel, Jürgen. *Prognose von Zeitreihen - Eine Einführung für Wirtschaftswissenschaftler*. 1. Aufl. Wiesbaden: Springer Gabler, 2015.
- Wang, Yi, Dahua Gan, Mingyang Sun, Ning Zhang, Zongxiang Lu, und Chongqing Kang. „Probabilistic Individual Load Forecasting Using Pinball Loss Guided LSTM“. *Applied Energy* 235 (Februar 2019): 10–20. <https://doi.org/10.1016/j.apenergy.2018.10.078>.
- Wechsler, D. (1964). *Die Messung der Intelligenz Erwachsener*. 3. Aufl. 1964. Bern: Huber.
- Whittle, Peter. *Hypothesis testing in time series analysis*. Bd. 4. Uppsala: Almqvist & Wiksells boktr., 1951.
- Xishuang Dong, Lijun Qian, und Lei Huang. „Short-Term Load Forecasting in Smart Grid: A Combined CNN and K-Means Clustering Approach“. In *2017 IEEE International Conference on Big Data and Smart Computing (BigComp)*, 119–25. Jeju Island, South Korea: IEEE, 2017. <https://doi.org/10.1109/BIGCOMP.2017.7881726>.
- Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*, 31(7), 1235–1270. https://doi.org/10.1162/neco_a_01199

- Zakeri, Behnam, Katsia Paulavets, Leonardo Barreto-Gomez, Luis Gomez Echeverri, Shonali Pachauri, Benigna Boza-Kiss, Caroline Zimm, u. a. „Pandemic, War, and Global Energy Transitions“. *Energies* 15, Nr. 17 (2022): 6114. <https://doi.org/10.3390/en15176114>.
- Zhang, Guoqiang, B. Eddy Patuwo, und Michael Y. Hu. „Forecasting with Artificial Neural Networks“: *International Journal of Forecasting* 14, Nr. 1 (März 1998): 35–62. [https://doi.org/10.1016/S0169-2070\(97\)00044-7](https://doi.org/10.1016/S0169-2070(97)00044-7).
- Zhu, Xianghe, und Min Shen. „Based on the ARIMA Model with Grey Theory for Short Term Load Forecasting Model“, o. J.