

EIN METHODISCHES FRAMEWORK FÜR DIFFUSION-BASED MPC IN HOCHBELASTETEN VERTEILNETZEN

Maik PLENZ¹, Andreas STADLER², Detlef SCHULZ²

Einleitung

Die Analyse, Prognose und Zustandsbewertung von Verteilnetzen und deren Auslastungen gilt als ein Teilaspekt zur Reduktion des Netzausbaubedarfes. Dies wird angetrieben durch die Energiewende und den Ausbau von dezentralen, neuartigen Lasten, wie Elektrofahrzeuge sowie Wärmepumpen. Sowohl eingeschleifte Niederspannungsnetze (NS) – die meist ohne genaue Kenntnis des Betriebsverhaltens versorgt werden – als auch Industrien, EE-Erzeugungseinheiten und große Ladehubs erschweren die Einschätzung aktueller und zukünftiger Auslastungen des Mittelspannungsnetzes (MS). Insbesondere die Integration von Hochleistungsladeinfrastruktur (Megawatt Charging Systems, MCS) für den elektrifizierten Schwerlastverkehr/ÖPNV stellt Verteilnetzbetreiber vor neue Herausforderungen und einen höheren Bedarf an Prognosefähigkeit der Auslastung verbauter Netzassets. Diese MCS treten sowohl einzeln als auch in großen Ladehubs in Verbänden in bspw. LKW-Depots oder Bus-Depots (siehe [1]) sowie an zukünftigen Ausbauten an Fern- und Schnellstraßen im Rahmen der geplanten Trans-European Transport Network (TEN-T) - Korridore auf [2]. Im Gegensatz zu konventionellen Verbrauchern weisen LKW/Bus-Depots eine hohe stochastische Volatilität mit extremen Leistungsspitzen auf. Insbesondere die MS ist von dem stärkeren Ausbaubedarf an zentrierter Hochleistungs-LIS betroffen und rückt daher aus technischer Sicht in den Fokus der Betrachtung [3,4]. Deterministische Prognoseverfahren, wie sie in klassischen Model Predictive Control (MPC) Ansätzen verwendet werden, tendieren zur Glättung dieser Spitzen und unterschätzen somit das Risiko von Grenzwertverletzungen, meist bedingt durch jene Einflüsse, die in der Netzanalyse die Worst-Case-Szenarien darstellen. Das Ziel des Papers ist es, einen neuartigen Ansatz zur Prognose des Netzverhaltens vorzustellen und ein Framework für zukünftige Analysen zu entwickeln. Der sogenannte Diffusion-based Generative MPC ist eine bisher nicht verwendete Variante der Vorhersagekontrolle, die eine Wahrscheinlichkeitsverteilung der Outputs bedingt durch die gewählten Input-Größen definiert und damit sowohl generelle Prognosen als auch Worst-Case-Verhalten umfassend abbilden kann. Dieses Papier fokussiert sich in einem ersten Schritt auf die Erläuterung des Ansatzes, den Vergleich mit weiteren Modellen und die Abbildung und Definition des Frameworks. In weiteren Arbeiten wird dieses Framework genutzt, um ein auf realen Daten beruhendes MS-referenznetz als auch unterlagerte NS-referenznetze inklusive zugehöriger Lasten und Erzeugungseinheiten und weiterer Input-Variablen zu simulieren. Aufgrund der Neuartigkeit des Ansatzes wird eine vertiefte Darstellung der Vorteile, des Aufbaus und der zukünftigen Analysen notwendig. In der Kurzfassung wird in den folgenden Kapiteln Auszüge der Beschreibung des Diffusion MPC und ein erster Einblick in das Framework ermöglicht.

Literarische Einordnung

Engpass- und Lastmanagement in Verteilnetzen

Die Integration von Elektrofahrzeugen (EV) und E-LKW in das Verteilnetz stellt die Netzstabilität und Resilienz vor erhebliche Herausforderungen. Zahlreiche Studien [5-8] belegen, dass die ansteigende EV-Penetration zu erhöhten Spannungsvarianzen sowie Überlastungen von Transformatoren und Umspannwerken führen kann. Während unkoordiniertes Laden die Stabilität des Verteilnetzes gefährden kann [5], zeigen andere Arbeiten, dass Lademanagement die EV-induzierten Lastspitzen mindern können [5-9]. Um den Ladebedarf (meist für NS) vorherzusagen und Lastspitzen zu minimieren, kommen neben linearen und statischen Verfahren [5], meist neuronale Netze [10, 11] sowie lineare Optimierungsverfahren [12] zum Einsatz. Komplexere Ansätze nutzen agentenbasierte Modelle und Deep Reinforcement Learning (DRL), um Verbrauchsprognosen zu erstellen [13, 14].

¹ Helmut-Schmidt-Universität Hamburg, Holstenhofweg 85, 22043 Hamburg, Tel: +49 40 6541-2988, Mail: maik.plenz@hsu.hamburg , www.hsu-hh.de

² Helmut-Schmidt-Universität Hamburg, Holstenhofweg 85, 22043 Hamburg, Mail: {Vorname}.{Nachname}@hsu.hamburg , www.hsu-hh.de

Diffusion-based generative MPC

Die modellprädiktiven Regelungen (MPC) in elektrischen Verteilsystemen haben ihren Ursprung im Verfahren des Optimal Power Flow (OPF). Beim OPF wird – häufig unter Nutzung des Newton-Raphson-Verfahrens – ein Optimierungsproblem gelöst, das darauf abzielt, den Betrieb eines Stromversorgungssystems unter Berücksichtigung der Betriebsmittelzustände [15]. Eine Übersicht von Anwendungsgebieten des OPF findet sich bspw. unter [16]. Eine Weiterentwicklung stellen MPC-Ansätze dar, die eine Voraussage von Erzeugung und Verbrauch im Verteilnetz über einen definierten Zeithorizont in die Entscheidung einbeziehen [17]. Klassische Verfahren stoßen jedoch bei der Integration volatiler Lasten an ihre Grenzen. Anstatt daher lediglich einen einzelnen Netzzustand vorherzusagen, nutzt der hier vorgestellte Ansatz ein Denoising Diffusion Probabilistic Model (DDPM), um die Wahrscheinlichkeitsverteilung möglicher Netzzustände zu generieren. Dies ermöglicht die explizite Abbildung seltener, aber kritischer Überlagerung von Lastspitzen. Darauf aufbauend optimiert ein verteilungsrobuster Regler (Distributionally Robust Control) die Flexibilität vorausschauend gegen diese Risikoszenarien, kombiniert bezeichnet als Diffusion-based Generative MPC.

Methodik / Ergebnisse

Das in Abb. 1 vorgestellte Framework verdeutlicht den hierarchischen Aufbau der Co-Simulation zur Verhinderung und Bewirtschaftung von Netzengpässen in der MS. Hierbei werden volatile und leistungsintensive Ladeinfrastrukturen (MCS-LIS), aggregierte Flexibilität in der Niederspannung (wie WP, EV, PV) und Flexibilität in der Mittelspannung (EE-Anlagen, Industrie-Flexibilitäten) als steuerbare Ressourcen integriert. Der Kern des Ansatzes ist ein Diffusion-based Generative Model Predictive Control, der anstelle feststehender punktueller Prognosen durch die Verwendung eines Denoising-Prozesses die Wahrscheinlichkeitsverteilung zukünftiger Netzzustände als Vielzahl netztauglicher Szenarien K generiert. Diese generative Methode ermöglicht die Darstellung von Korrelationen und Regressionen, um seltene Worst-Case-Szenarien abzubilden. Dies wird u.a. umgesetzt durch die Einbringung von Sicherheitsgrenzen als probabilistische Conditional-Value-at-Risk (CVaR) Constraints [18], welche in die Optimierung eingehen. Der nachgelagerte Optimierer löst ein quadratisches Problem, das unter Einhaltung dieser Sicherheitsbreiten sowie regulatorischer Restriktionen (z. B. §14a EnWG, EEG-Abregelungsvorgaben) eine Kostenfunktion J minimiert. Dadurch dient der Ansatz für eine risikosensitive, vorausschauende Netzsteuerung, die die Aufnahmekapazität des Netzes dynamisch maximiert, ohne die Versorgungssicherheit zu gefährden.

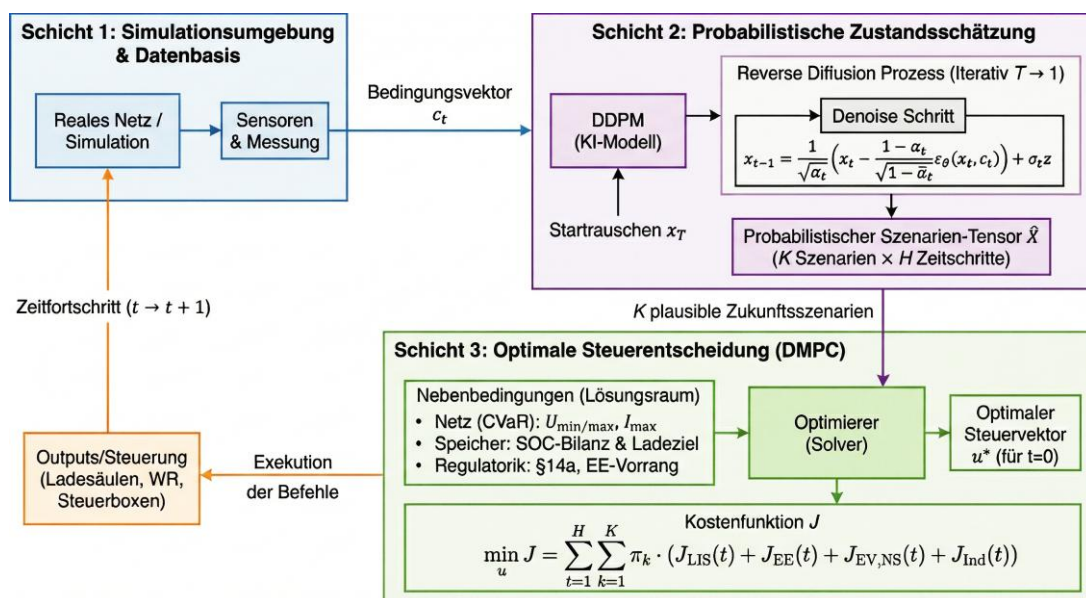


Abbildung 1: Ansatz Framework und Simulationsaufbau

Danksagung

Diese Forschungsarbeit wird durch dtcc.bw – Zentrum für Digitalisierungs- und Technologieforschung der Bundeswehr gefördert. dtcc.bw wird von der Europäischen Union – NextGenerationEU finanziert.

Referenzen

- [1] Plenz, M, Stadler, A., et al. (2025) *Aktueller Stand der Großladeinfrastruktur – Reallabor am Kronprinzkaai*. In: Hamburger Beiträge zum technischen Klimaschutz – Energie im Wandel: Forschungsperspektiven für Wasserstoff, Elektromobilität und Netzinnovation, Helmut-Schmidt-Universität / Universität der Bundeswehr, Professur für Elektrische Energiesysteme, Hamburg, Februar 2025, Bd. 6, S. 153ff, ISSN 2698-8801 ISBN 978-3-86818-257-6 DOI 10.24405/17162.
- [2] Schade, W., et al. (2024) *Support Study on the Climate Adaptation and Cross-Border Investment Needs to Realise the TEN-T Network*. No. MI-01-24-000-EN-N. 2024.
- [3] Jahic, A. (2024) *Towards optimal operation of large-scale electric bus depots: Load analysis, load management, scheduling, and flexibility assessment*. Dissertation, Helmut-Schmidt-Universität / Universität der Bundeswehr Hamburg.
- [4] Jahic, A.; Avdevious, E.; Plenz, M.; Schulz, D. (2024) *Synthetic Load Profile for Electric Bus Depots With Centralized Charging Concept*. In: IEEE PES Innovative Smart Grid Technologies Europe (ISGT EUROPE), Dubrovnik, Croatia, 14.-17. Oktober 2024 DOI: 10.1109/ISGTEUROPE62998.2024.10863375.
- [5] Plenz, M.; Stadler A.; Schulz, D. (2024) *Mitigating Grid Peaks in E-Mobility Charging A Comparative Evaluation of §14a EnWG and Priority-Driven Load Reduction Approaches*. In: 2024 13th International Conference on Renewable Energy Research and Applications (ICRERA), Nagasaki, Japan, pp. 917-923, doi: 10.1109/ICRERA62673.2024.10815409.
- [6] Khaki, B.; Chung, Y. W.; Chu, C.; Gadh, R. (2019) *Probabilistic Electric Vehicle Load Management in Distribution Grids*. In: Proceedings of the IEEE Transportation Electrification Conference and Expo (ITEC), IEEE, Detroit, MI, USA, pp. 1–6, 19–21 June 2019.
- [7] Singh, J.; Tiwari, R. (2019) *Impact analysis of different charging models for optimal integration of plug-in electric vehicles in distribution system*. IET J. Eng., pp. 4728–4733.
- [8] Kilic, E.; Akil, M.; Bayindir, R.; Sebati, A.; Malek, R. (2021) *Electric Vehicles Charging Management with Monte Carlo Simulation*. In: 2021 10th International Conference on Renewable Energy Research and Application (ICRERA), Istanbul, Turkey, pp. 423-427, doi: 10.1109/ICRERA52334.2021.9598807.
- [9] Kucevic, D.; Englberger, S.; Sharma, A.; et al., (2021) *Reducing grid peak load through the coordinated control of battery energy storage systems located at electric vehicle charging parks*. In: Appl. Energy 2021, Vol. 295, 116936, 2021.
- [10] Jahangir, H.; Tayarani, H.; Ahmadian, A.; et al. (2019) *Charging demand of plug-in electric vehicles: Forecasting travel behavior based on a novel rough artificial neural network approach*. J. Clean. Prod. 2019, Vol. 229, pp. 1029–1044, 2019.
- [11] Topic, J.; Skugor, B.; Deur, J. (2019) *Neural network-based modeling of electric vehicle energy demand and electric range*. Energies 2019, Vol. 12, 1396, 2019
- [12] Kucevic, D.; Englberger, S.; Sharma, A.; et al., (2021) *Reducing grid peak load through the coordinated control of battery energy storage systems located at electric vehicle charging parks*. Appl. Energy 2021, Vol. 295, 116936.
- [13] Fu, Y. . Versen, D. S.; Plenz, M.; Stiemer, M.; Schulz, D. (2023) *Electric Vehicle Charging Management for Avoiding Transformer Congestion Using Policy-based Reinforcement Learning, 2023 IEEE PES Innovative Smart Grid Technologies Europe (ISGT EUROPE)*, Grenoble, France, 2023, pp. 1-5, doi: 10.1109/ISGTEUROPE56780.2023.10407357.
- [14] Hu, Y.; Li, W.; Xu, K.; Zahid, T.; et al. (2017) *Energy management strategy for a hybrid electric vehicle based on deep reinforcement learning*. Appl. Sci. 2017, Vol. 8, 187, 2017.
- [15] Frank, S.; Rebennack, S. (2016) *An introduction to optimal power flow: Theory, formulation, and examples*, IIE Transactions, 48:12, 1172-1197, DOI: 10.1080/0740817X.2016.1189626
- [16] Huneault, M. ; Galiana, F. D. (1991) *A survey of the optimal power flow literature*. In: IEEE Transactions on Power Systems 6, May, Nr. 2, S. 762–770
- [17] Hayes, B. P. ; Prodanovic, M. (2016) *State Forecasting and Operational Planning for Distribution Network Energy Management Systems*, in IEEE Transactions on Smart Grid, vol. 7, no. 2, pp. 1002-1011, March 2016, doi: 10.1109/TSG.2015.2489700.
- [18] Xuan, A.; Shen, X.; Guo, Q.; Sun, H. (2021) *A conditional value-at-risk based planning model for integrated energy system with energy storage and renewables*, Applied Energy, Volume 294, 2021, 116971, ISSN 0306-2619, <https://doi.org/10.1016/j.apenergy.2021.116971>.