

# EIN METHODISCHES FRAMEWORK FÜR DIFFUSION-BASED MPC IN HOCHBELASTETEN VERTEILNETZEN

Maik PLENZ\*, Andreas STADLER, Detlef SCHULZ

Helmut-Schmidt-Universität/Universität der Bundeswehr Hamburg,  
Holstenhofweg 85, 22043 Hamburg,  
Tel: +49 40 6541-2988, Mail: [maik.plenz@hsu.hamburg](mailto:maik.plenz@hsu.hamburg) , [www.hsu-hh.de](http://www.hsu-hh.de)

**Kurzfassung:** Dieses Paper stellt das Diffusion-based Generative MPC (DMPC) vor, einen Ansatz zur Steuerung hochbelasteter Verteilnetze unter dem Einfluss von Unsicherheit. Durch den Einsatz von Denoising Diffusion Probabilistic Models werden anstelle einzelner Punktprognosen vielfältige Szenarien entwickelt, um aufkommende Risiken ausreichend abzubilden. Ein nachgelagerter Optimierer minimiert das Modell unter Berücksichtigung von Nebenbedingungen, was eine optimierte Netzführung und –bewertung ermöglicht. Nachfolgend wird das Framework detailliert vorgestellt.

**Keywords:** Deep MPC, Multi-Ebenen Simulation, Lastmanagement, Verteilnetz, Elektrofahrzeuge, MCS

## 1 Einleitung

Die Analyse, Prognose und Zustandsbewertung von Verteilnetzen und deren Auslastungen gilt als ein Teilaspekt zur Reduktion des zukünftigen Netzausbaubedarfes. Angetrieben durch die Energiewende und den Ausbau von dezentralen, volatilen Lasten, wie Elektrofahrzeugen und Wärmepumpen wird auch eine optimierte Netzführung und –steuerung immer relevanter. Sowohl eingeschleifte Niederspannungsnetze (NS) – die meist ohne genaue Kenntnis des Betriebsverhaltens versorgt werden – als auch Industrieverbraucher, Erneuerbare Energien (EE)-Erzeugungseinheiten und große Ladehubs erschweren die Einschätzung aktueller und zukünftiger Auslastungen des Mittelspannungsnetzes (MS) und unterlagerter Netzgebiete. Zusätzlich erschwert die Integration von Hochleistungsladeinfrastruktur (High Power Charger, HPC und Megawatt Charging Systems, MCS) für den elektrifizierten Schwerlastverkehr bzw. Ladeinfrastruktur (LIS) für ÖPNV-/Logistik-Depots die Steuerung und Ausbauplanung und fordert einen höheren Bedarf an Prognosefähigkeit zur aktuellen und prognostizierten Auslastung verbauter Netzassets um potentielle Kapazitätsengpässe oder Überlastungen frühzeitig zu begegnen. 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 diese eine hohe stochastische Volatilität mit teilweise extremen Leistungsspitzen und unerwarteten Gleichzeitigkeiten auf. Insbesondere die MS ist von dem stärkeren Ausbaubedarf an zentrierter Hochleistungs-LIS betroffen und rückt daher aus technischer Sicht in den Fokus dieser Arbeit [3,4]. Herkömmliche deterministische Prognoseverfahren, darunter klassische Model-Predictive-Control-Ansätze (MPC), neigen dazu, auftretende Leistungsspitzen zu glätten, was im ungünstigsten Fall eine Unterdimensionierung der Betriebsmittel zur Folge haben kann. Das Ziel des Papers ist es, einen innovativen Prognoseansatz des

Netzverhaltens vorzustellen und ein Framework zu entwickeln. Der sogenannte Diffusion-based Generative MPC ist eine neuartige Methode, die eine Wahrscheinlichkeitsverteilung der Outputs bedingt durch die gewählten Input-Größen definiert und damit sowohl generelle Prognosen als auch Worst-Case-Verhalten abbilden kann. Dieses Papier fokussiert sich auf die Erläuterung des Ansatzes, den Vergleich mit weiteren Modellen und die Definition des Frameworks. Im Papier wird versucht die Originalbegrifflichkeiten beizubehalten, weswegen englische Begriffe vordergründig verwendet werden.

## 2 Literarische Einordnung

### 2.1 Engpass- und Lastmanagement in Verteilnetzen

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

### 2.2 Diffusion-based generative MPC

Modellprädiktive Regelungen bzw. Model-Predictive-Control (MPC) in elektrischen Verteilsystemen finden ihren Ursprung im Optimal Power Flow (OPF). Beim OPF wird ein Optimierungsproblem gelöst, das darauf abzielt, für ein Stromnetz unter Berücksichtigung der Betriebsmittelzustände die bestmögliche Lösung einer definierten Zielfunktion (Kostenminimierung, Betriebsmittelauslastungsreduzierung, etc.) zu entwickeln [15]. Eine Übersicht von Anwendungsgebieten des OPF findet sich unter [16]. Eine Weiterentwicklung stellen MPC-Ansätze dar, die bspw. eine Voraussage von Erzeugung und Verbrauch über einen definierten Zeitraum einbeziehen [17]. Grundlage des neuen Ansatzes bietet das nach [19] vorgestellte Modell des Diffusion-based MPC, wo ein MPC-Optimierer – der schrittweise mathematischer Solver verwendet – durch einen generativen Diffusionsprozess ersetzt wird. Also, anstatt den einzigen nächsten Schritt zu berechnen, lernt das Modell die Verteilung ganzer potentieller Zustände und Aktionen über den Zeithorizont. Abweichend vom in dieser Arbeit vorgestellten Ansatz, verwendet [19] das Diffusionsmodell als kombinierten Planer für Handlungssequenzen im Bereich der Robotik (Policy-Diffusion).

Allgemein wird der Ablauf *Stichprobe, Bewertung und Einordnung* umgesetzt:

- Stichprobe: Das Diffusionsmodell generiert parallel eine Vielzahl möglicher Handlungsstränge aus Rauschen.
- Bewertung: Jeder generierte Strang wird anhand einer separat definierten Kostenfunktion bewertet.
- Einordnung: Die Projektion mit der besten Bewertung wird ausgeführt.

Anstatt einen einzelnen Netzzustand vorherzusagen, wird im geplanten Ansatz ein Denoising Diffusion Probabilistic Model (DDPM) umgesetzt, um Wahrscheinlichkeitsverteilungen potenzieller Netzzustände zu erhalten. Dies ermöglicht die Abbildung seltener, kritischer Lastspitzen. Darauf aufbauend optimiert ein Regler (Distributionally Robust Control) mögliche Regelgrößen vorausschauend gegen diese Szenarien inkl. Netzgrenzen; das Diffusion-based Generative MPC. Ein Vergleich mit bestehenden Ansätzen findet sich in Tabelle 1.

TABELLE 1: VERGLEICH DES DIFFUSION-BASED MPC MIT RELEVANTEN ANSÄTZEN

Ansatz	Schwäche	Vorteil DMPC	Quellen / Beispiele
Reinforcement Learning (RL)	Trainiert für feste Belohnungsfunktion. Neue Beschränkungen erfordern Neutraining.	Kann neue Beschränkungen kurzfristig integrieren, ohne von vorne zu beginnen (z.B. §14a EnWG).	[13,14,20]
Klassisches MPC	Rechenintensiv bei nicht-linearen Problemen.	Findet bessere Optima.	[21,22]
Transformer-Based Planning	Deterministisch; tendiert allgemein zu "Mittelwert"-Lösungen.	Probabilistisch; deckt die volle Bandbreite an Möglichkeiten ab.	[24]
GANs (Generative Adversarial Networks)	Typische Szenarien werden gelernt, Worst-Cases ignoriert.	Integriert Worst-Case Szenarien.	[23]

### 3 Framework

Das vollumfängliche Framework ist in Abb. 3 zusammengefasst. Im folgenden Kapitel wird auf die einzelnen Schichten eingegangen und diese näher erläutert.

#### 3.1 Schicht 1 (Simulationsumgebung & Datenbasis)

Damit das Diffusionsmodell trainiert und in den MPC übergeben werden kann, muss ein Zustandsvektor  $c_t$  in (1) definiert werden. Die Einbettung erfolgt in ein MS-Netz (10 bzw. 20 kV) – inkl. den Knoten zur Anbindung an das überlagerte externe Netz, den Knoten der MCS-Depots, den Knoten der Industrie und den Transformatoren zu den NS-Netzen. Diese NS-Netze werden nicht je Strang oder Netzteil simuliert, sondern als aggregierte Last am Ortsnetztransformator. Die notwendigen Variablen für den Zustandsvektor sind in Tabelle 2 zusammengefasst.

TABELLE 2: ÜBERSICHT DER RELEVANTEN VARIABLEN FÜR DEN ZUSTANDSVEKTOR  $c_t$ .

Datenpunkt	Herkunft	Variable	Erklärung
Zeit	Kalender	$t$ ggf. $\sin t \cos t$	Zeit, nach Bedarf unterteilt nach Zeiteinheiten (ggf. zyklisch)
Wetter	Wetterdienst (DWD, etc.)	$G_{sol}, T_{amb}, v_{Wind}$	Globalstrahlung ( $G_{sol}$ in $W/m^2$ ) Temperatur ( $T_{amb}$ in $^{\circ}C$ ) Windgeschwindigkeit ( $v_{Wind}$ in $m/s$ )

<b>Lasten</b>			
LKW/Busse (MS)	LKW-/ Bus-Depot Simulator, Messdaten	$SOC_{LKW, Bus}(t)$ $N_{LKW, Bus}(t)$ $P_{LKW, Bus}(t)$	Ladezustand je LKW/Bus ( $SOC_{LKW, Bus}$ in %), Anzahl Fahrzeuge ( $N_{LKW, Bus}$ ), Ladeleistung ( $P_{LKW, Bus}$ in kW)
Industrielasten (MS)	Standardlastprofil (SLP) Gewerbe, Landwirtschaft	$P_{Ind}(t)$	Grundlast der Industrieverbraucher ( $P_{Ind}$ in kW)
Haushalte (NS)	SLP, Messdaten	$P_{HH}(t)$ $= \forall P_{HH} \text{ je ONT}(t)$	Grundlast der Haushalte, kumuliert ( $\forall P_{HH} \text{ je ONT}$ in kW)
E-KFZ (NS)	Messdaten	$P_{EV}(t)$ $= \forall P_{EV} \text{ je ONT}(t)$	Ladeleistung privater PKW, bei Bedarf kumuliert je ONT ( $P_{EV}$ in kW)
Wärmepumpen (NS)	Thermisches Modell Messdaten	$P_{WP}(t) = \forall P_{WP} \text{ je ONT}(t)$	Elektrische Wärmepumpenlast ( $T_{amb}$ - abhängig), bei Bedarf kumuliert je ONT ( $P_{WP}$ in kW <sub>ele</sub> )
<b>Erzeugung (in kW)</b>			
PV (MS, NS)	Wetter → Leistung Messdaten	$P_{PV}(t)$	Verfügbare Leistung aus PV in MS (PV-Parks), Aufdachanlagen in NS
Wind (MS)	Wetter → Leistung Messdaten	$P_{Wind}(t)$	Verfügbare Leistung aus Wind
<b>Netzparameter</b>			
Grenzwerte	Normen bspw. DIN 50160	$U_{min/max}$ $I_{max(Leitung)}$ $S_{max(Trafo)}$	Spannungsgrenzen in NS und MS Betriebsmittelgrenzen Kabel und Transformatoren (in V, A, VA%)

Der Zustandsvektor  $c_t$  nach (1) umfasst die Zeitinformationen  $z_{Zeit}$ , Wetterdaten  $w_{Wetter}$ , die Informationen der Mittelspannung  $x_{MS}$  und Niederspannung  $x_{NS}$ .

$$c_t = [z_{Zeit}, w_{Wetter}, x_{MS}, x_{NS}] \quad (1)$$

$$c_t = \left[ \underbrace{\sin t, \cos t}_{\text{Zeit}}, \underbrace{G_{sol}, T_{amb}, v_{Wind}}_{\text{Wetter}}, \underbrace{SOC_{LKW}, P/N_{LKW}, P_{Ind}, P_{PV, Wind MS}}_{\text{Mittelspannung}}, \underbrace{P_{HH}, P_{EV}, P_{PV NS}, P_{WP}}_{\text{Niederspannung}} \right] \quad (2)$$

Neben den Last- und Erzeugungsdaten aus Tabelle 2 umfasst das Netzmodell die Topologieparameter. Hierzu zählen die Netzgraphen sowie die normierten oder VNB-spezifischen Sicherheitsgrenzen für Knotenspannungen ( $U_{min/max}$ ) und thermische Belastbarkeiten ( $I_{max(Leitung)}, S_{max(Trafo)}$ ).

### 3.2 Schicht 2 (Probabilistische Zustandsschätzung)

Hier findet der Übergang der Daten (Schicht 1) zu probabilistischen Szenarien statt. Das Ziel ist es, herauszufinden welche Bandbreite an Zuständen plausibel ist. Das Zentrum dieses Schrittes bildet das Conditional Denoising Diffusion Probabilistic Model (c-DDPM) [25]. Der Ablauf der zweiten Schicht ist in Abb. 1 zusammengefasst.




Abbildung 1: Ablauf der Schicht 2.

Nach einer Initialisierung, bei welcher  $K$  verschiedene Vektoren (Szenarien) aus Gaußischem Zufallsrauschen erzeugt werden, folgt das Denoising (Entrauschen). Hier führt das Modell  $\epsilon_\theta$  eine schrittweise Entrausung unter Nutzung von  $c_t$  nach (3) durch.

$$x_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left( x_t - \frac{1 - \alpha_t}{\sqrt{1 - \bar{\alpha}_t}} \cdot \epsilon_\theta(x_t, t, c_t) \right) + \sigma_t \cdot z \quad (3)$$

Im Prinzip beschreibt (3) den Übergang vom verrauschten Zustand  $x_t$  zum entrauschten Zustand  $x_{t-1}$ , der mittels des neuronalen Netzes  $\epsilon_\theta$  (realisiert als konditionales 1D-ResNet zur Erfassung zeitlicher Abhängigkeiten [26]) bestehend  $x_t$ , den Zeitschritt  $t$  und dem Zustandsvektor  $c_t$ , einer zugehörigen Signalrate  $\alpha_t$  und einem Zufügen eines geringen gaußschen Zufallsrauschen  $z$  inkl. Varianz  $\sigma_t$  definiert wird. Hierbei leiten sich die Parameter der Signalrate  $\alpha_t$  und  $\sigma_t$  direkt aus der selbstgewählten Abweichung  $\beta_t$  ab:  $\alpha_t = 1 - \beta_t$  bzw.  $\sigma_t = \sqrt{\beta_t}$ . Das kumulative Produkt  $\bar{\alpha}_t$  gibt an, wie viel Originalsignal im Zeitschritt  $t$  theoretisch noch übrig ist nach (4).

$$\bar{\alpha}_t = \prod_{s=1}^t \alpha_s \quad (4)$$

Im abschließenden Schritt  $t = 0$  ist  $\sigma_t = 0$ , damit das Endergebnis rauschfrei ist. Der  $\sigma_t \cdot z$ -Anteil reduziert das Risiko, dass das Modell zu schnell auf dem Mittelwert runterbricht, und ermöglicht damit verschiedene Lösungen.

Am Ende stehen  $K$  Szenarien. Das Resultat ist ein 3-dimensionaler Tensor  $\hat{X}$ , schematisch in Abb. 2 dargestellt, mit den Dimensionen:  $K$  Szenarien  $\times H$  Zeitschritte  $\times N$  Netzknöten.

Inhaltlich ergibt die Schicht 2 u. a. Informationen zur:

- Knotenspannungen ( $U$ ): Wie verhält sich  $U$  an kritischen Knoten in den Szenarien?
- Auslastungen ( $I/I_{\max}$ ): Wie stark sind Leitungen und Transformatoren belastet?
- Lastflüssen ( $P$ ): Wie viel Leistung wird an den Knoten aufgenommen/eingespeist?

### 3.3 Schicht 3 (Optimale Steuerentscheidung)

Das Ziel der Schicht 3 ist es, jenes  $u_t$  zu finden, welches über alle Szenarien (aus Schicht 2) hinweg die geringsten zu erwartenden Kosten  $J$  verursacht, nach (5).

$$\min_u J = \sum_{t=1}^H \sum_{k=1}^K \pi_k \cdot (J_{\text{LIS}}(t) + J_{\text{EE}}(t) + J_{\text{EV,NS}}(t) + J_{\text{Ind}}(t)) \quad (5)$$




Abbildung 2: Datentensor  $\hat{X}$  nach dem c-DDPM. Erstellt unter Zuhilfenahme von generativer KI.

Die Steuerentscheidungen werden beeinflusst durch die Einflussgrößen aus Tabelle 3, inkl. zugehörigen Gewichtung  $\omega$ .

TABELLE 3: ÜBERSICHT DER RELEVANTEN STEUERGRÖßEN.

Hochleistungs-/Megawatt LIS von LKW/Bussen in Depots (MS)	$J_{\text{LIS}}(t) = \omega_{\text{LIS}} \cdot (P_{\text{Ref,LIS},t} - P_{\text{Set,LIS},t})^2$	(6)
Regelung und Steuervorgaben der EE-Anlagen (MS, NS)	$J_{\text{EE}}(t) = \omega_{\text{EE}} \cdot (P_{\text{Curt,NS}} + P_{\text{Curt,MS}})^2$	(7)
Lastmanagement §14a EnWG (NS)	$J_{\text{EV,NS}}(t) = \omega_{\text{EV}} \cdot \sum (\Delta P_{\text{EV}})^2$	(8)
Industrieflexibilität, vertraglich geregelte Einregelungen (MS)	$J_{\text{Ind}}(t) = \omega_{\text{Ind}} \cdot (P_{\text{Ref,Ind}} - P_{\text{Set,Ind}})^2$	(9)

Der für diese Kostenminimierung vorliegende Lösungsraum wird durch die Nebenbedingungen aus Tabelle 4 definiert. Diese beziehen sich auf die getroffenen Vorgaben und Untersuchungsschwerpunkte, um die Netzstabilität unter Berücksichtigung der generierten Szenarien mittels Conditional Value at Risk (CVaR) zu garantieren.

TABELLE 4: ÜBERSICHT DER NEBENBEDINGUNGEN INKLUSIVE ERLÄUTERUNG.

<b>Netzicherheit</b> (Spannungsuntergrenzen/obergrenzen, Thermische Belastung von Leitungen & Trafos)	$U_{n,t}$ ... Spannung am Knoten n zum Zeitpunkt $t$ (p.u.)	$CVaR_{\alpha}^{\text{low}}(U_{n,t}) \geq 0,9 \cdot U_{\text{Nenn}}$
	$U_{\text{Nenn}}$ ... Unterer Grenzwert (V)	
	$CVaR_{\alpha}^{\text{low/high}}$ ... Untere/Obere $\alpha$ -Quantile der Spannung in den Szenarien	$CVaR_{\alpha}^{\text{high}}(U_{n,t}) \leq 1,1 \cdot U_{\text{Nenn}}$
	$I_{l,t}$ ... Stromfluss auf der Leitung $l$ (A)	
<b>LKW-LIS</b> (SOC-Dynamik,	$S_{tr,t}$ ... Scheinleistung am Transformator $tr$ (kVA)	$CVaR(S_{tr,t}) \leq S_{tr,\text{max}}$
	$I_{\text{max}}, S_{\text{max}}$ ... Thermische Grenzwerte der Betriebsmittel	
	$SOC_t$ ...SOC der Fahrzeugbatterie zu $t$ (%)	$SOC_{t+1} = SOC_t + \eta \cdot P_{\text{Set,LIS},t} \cdot \Delta t$
	$\eta$ ...Ladewirkungsgrad	(11)
	$P_{\text{Set,LIS},t}$ ...Zugeführte Ladeleistung (kW)	$SOC_{t=\text{T(Dept)}} \geq SOC_{\text{Target}}$

<p>Ladeziel und Leistungsgrenzen)</p>	<p><math>T(Dept)</math>...Zeitpunkt der Abfahrt  <math>SOC_{Target}</math>...Erforderlicher SOC für nächste Fahrt (Vorgabe)  <math>P_{Inst,LIS}</math>...Installierte Ladesäulenleistung (kW)</p>	$0 \leq P_{Set,LIS,t} \leq P_{Inst,LIS}$
<p><u>Regelung und Steuervorgaben der EE-Anlagen</u> (Großanlagen &gt;100 kW und Anlagen in der NS)</p>	<p><math>P_{Curt,NS/MS,t}</math>... Abgeregelte Leistung (kW)  <math>P_{Avail,NS/MS,t}</math>... Anlagennennleistung (kW)  <math>\kappa_{NS}</math>...Abregelungsfaktor (z. B. 0,40 für Spitzenkappung auf 60%)</p>	$0 \leq P_{Curt,MS,t} \leq P_{Avail,MS,t}$ $0 \leq P_{Curt,NS,t} \leq \kappa_{NS} \cdot P_{Avail,NS,t}$
<p><u>Lastmanagement nach §14a EnWG</u> (Bedingter Eingriff, Zeitvorgabe)</p>	<p><math>P_{EV,t}</math>...Reduktion der Ladeleistung (Steuerung) (kW)  <math>P_{Base,t}</math>...Ungesteuerte Wallboxlast (kW)  <math>P_{Guard}</math>...Regelleistung für Notbezug (z.B. 4,2 kW)  <math>b_{dim,t}</math>...Binärvariable (<math>b_{dim,t} = 1</math>, Dimmung; <math>b_{dim,t} = 0</math>, inaktiv)  <math>T_{max}</math>...Maximale Dimmdauer pro Tag (z.B. 2h)</p>	$\Delta P_{EV,t} \leq \max(0, P_{Base,t} - P_{Guard})$ $\sum_{t=1}^{T_{Tag}} b_{dim,t} \cdot \Delta t \leq T_{max}$
<p><u>Industrie-Flexibilität</u> (Flexibilitätsband)</p>	<p><math>P_{Set,Ind,t}</math>...Freigegebene Leistung für den Industriebetrieb (kW)  <math>P_{Ref,Ind,t}</math>...Normaler Leistungsbedarf (Produktion)  <math>\delta_{Ind}</math>...Vertraglich vereinbarte Regelquote (z.B. 0,10 für 10%)</p>	$(1 - \delta_{Ind}) \cdot P_{Ref,Ind,t} \leq P_{Set,Ind,t} \leq P_{Ref,Ind,t}$

Das Ziel ist die Minimierung der Kostenfunktion  $J$  nach (5) über die Summe der Zeit  $t = 1 \dots H$  um den optimalen Steuervektor  $u^*_t$  zu finden (für  $t = 0$ ). Hieraus werden die Outputs, wie bspw. die Leistung zum LKW-Laden  $P^*_{Set,LIS}$ , die Einspeiseregulierung für EE-Anlagen  $P^*_{Curt,MS}$ , Dimm-Befehle gemäß §14a EnWG  $\Delta P^*_{EV}$  oder auch die Flexibilitätsleistung der Industrie  $P^*_{Set,Ind}$  ermittelt.

### 3.4 Rückführung und nächster Zeitschritt

Die Outputs (Steuervektor  $u^*$ ) gehen an Schicht 1 zurück, da die Anwendung der Outputs, wie bspw. Abregelungen erfolgen. Daraus verändert sich die Netzsituation, wobei gleichzeitig  $t = t + 1$  erfolgt. Darauf folgend werden alle neuen Dateninputs  $c_{t+1}$  eingebracht werden und es erfolgt eine Übergabe an Schicht 2.

## 4 Zusammenfassung

Die zunehmende Technologiedurchdringung von hoch-volatilen Lasten und hier besonders von LKW-/Bus-Ladeinfrastruktur im hohen kW- bis MW-Bereich und die Elektromobilität und Wärmepumpen in der Niederspannung reduzieren die Netzstabilität im Verteilnetz. Herkömmliche Prognoseverfahren wie modellprädiktive Regelung (MPC) führen zu geglätteten Lastspitzen und lassen Worst-Case Szenarien teilweise unbeachtet.

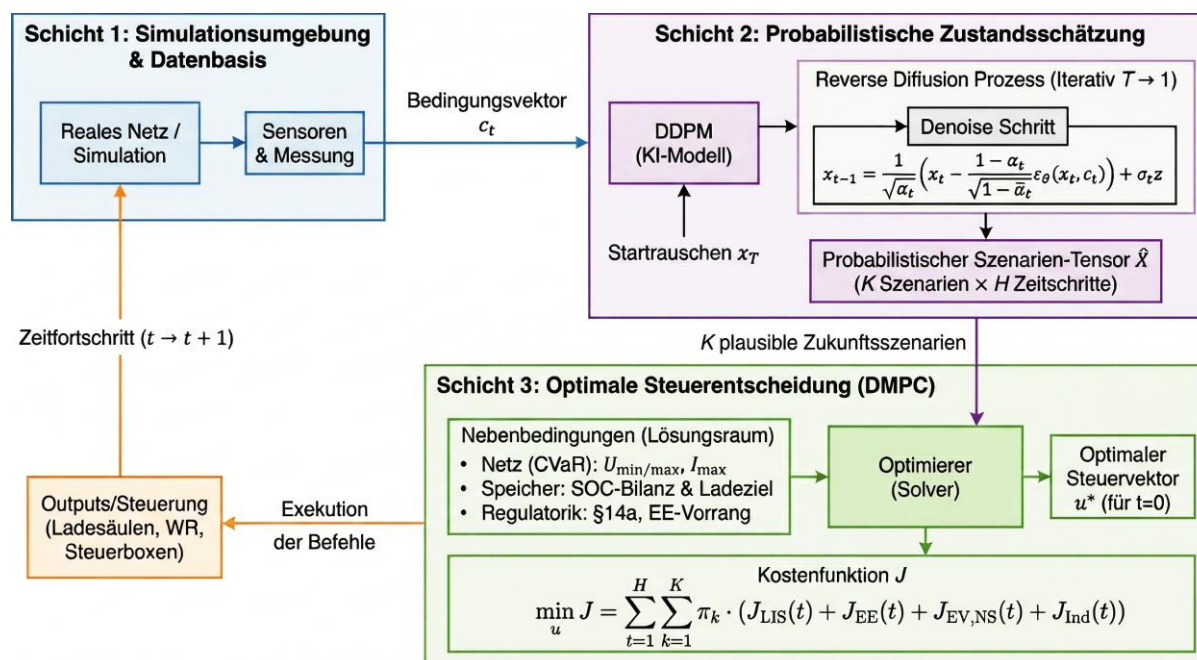


Abbildung 3: Framework des DMPC.

Dieses Paper stellt einen neuartigen Ansatz, das Diffusion-based Generative Model Predictive Control (DMPC) vor und fasst ihn in einem Framework in Abb. 3 zusammen. Der Ansatz setzt auf sogenannte Denoising Diffusion Probabilistic Models (DDPM), um mittels aktueller Messdaten und externen Informationen eine Verteilung der Wahrscheinlichkeit möglicher Netzzustände mithilfe verschiedener Szenarien zu erzeugen. Ein Decision Layer bestimmt daraufhin den optimalen Steuervektor, indem die erwarteten Kosten über alle Szenarien auf ein Minimum reduziert werden. Dabei gewährleisten Nebenbedingungen und Netzgrenzen die Einhaltung von Vorgaben. Das vorgestellte Framework ermöglicht zukünftig prädikative Netzsteuerung und umfassende Zustandsbewertungen, welche Abregelungen minimieren und die Resilienz erhöhen können. In weiteren Arbeiten wird dieses Framework genutzt, um ein auf realen Daten beruhendes MS-Netz als auch unterlagerte NS-Netze inklusive zugehöriger Lasten und Erzeugungseinheiten zu simulieren.

## 5 Danksagung

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

## 6 Referenzen

- [1] Plenz, M, Stadler, A., et al. (2025) *Aktueller Stand der Großladeinfrastruktur – Reallabor am Kronprinz Kai*. In: Hamburger Beiträge zum technischen Klimaschutz – Energie im Wandel: Forschungsperspektiven für Wasserstoff, Elektromobilität und Netzinnoation, 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, 2019.
- [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>.
- [19] Zhou, G.; et al. (2025) *Diffusion model predictive control*. In: Transactions on Machine Learning Research (05/2025) arXiv preprint arXiv:2410.05364.
- [20] Li, P.; Shen, J.; Yin, M.; Zhang, Y.; Wu, Z. (2022): *A Deep Reinforcement Learning Voltage Control Method for Distribution Network*, 2022 IEEE 5th International Electrical and Energy Conference (CIEEC), Nangjing, China, 2022, pp. 2283-2288, doi: 10.1109/CIEEC54735.2022.9846033.

- [21] Fernández-Zapico, D.; Kats, R.; Hofman, T.; Salazar, M. (2025): *Stochastic Model Predictive Control of Charging Energy Hubs with Probabilistic Forecasting*. 2025 European Control Conference (ECC), Thessaloniki, Greece, 2025, pp. 3325-3326, doi: 10.23919/ECC65951.2025.11187078.
- [22] Li, Y. (2021): *An Energy Management Method of Electric Vehicles Based on Stochastic Model Predictive Control*. 2021 IEEE 4th Advanced Information Management, Communicates, Electronic and Automation Control Conference (IMCEC), Chongqing, China, 2021, pp. 1757-1761, doi: 10.1109/IMCEC51613.2021.9482279.
- [23] Chen, Y., Wang, Y., Kirschen, D., & Zhang, B. (2018): *Model-free renewable scenario generation using generative adversarial networks*. IEEE Transactions on Power Systems, 33(3), 3265-3275.
- [24] Chen, L.; Lu, K.; Rajeswaran, A.; Lee, K.; et al. (2021): *Decision transformer: reinforcement learning via sequence modeling*. In Proceedings of the 35th International Conference on Neural Information Processing Systems (NIPS '21). Curran Associates Inc., Red Hook, NY, USA, Article 1156, 15084–15097.
- [25] Ho J.; Jain A.; Abbeel P.; (2020): *Denoising diffusion probabilistic models*. Adv Neural Inf Process Syst 2020;33:6840–51.
- [26] Li R.; Zhang X.; Hao W.; Wang T. (2026): *Improved one-dimensional residual network high-voltage DC diagnosis for high-precision fault identification*. PLOS ONE 21(1): e0341115. <https://doi.org/10.1371/journal.pone.0341115>