

KI im Netzbetrieb – Chance für die Energiewende?

Mike Vogt, Kurt Brendlinger, Arne Wessel, Marcel Dipp, Malte Sievert, Sebastian Wende-von Berg

Kontakt: Dr. Sebastian Wende-von Berg | +49 561 7294-298 | sebastian.wende-von.berg@iee.fraunhofer.de

Probabilistische Netzzustandsprognose

Motivation

Deterministische Prognosen bzw. Erwartungswertprognosen bilden in der Regel die Grundlage für Netzzustandsprognosen im Engpassmanagement (Redispatch 2.0) des Netzbetriebes. Diese Prognosen berücksichtigen aber Unsicherheiten der Wetterszenarien nur wenig und wenn doch, dann meist in Form von durchschnittlichen Fehlern bzw. Abweichungen.

Ensemblebasierte Prognosen (z.B. auf 20 verschiedenen gleichwertigen Wetterszenarien) können hier genauere Unsicherheitsabschätzungen liefern und somit die operativen Engpassmaßnahmen effizienter, kostengünstiger und CO₂ sparer gestalten.

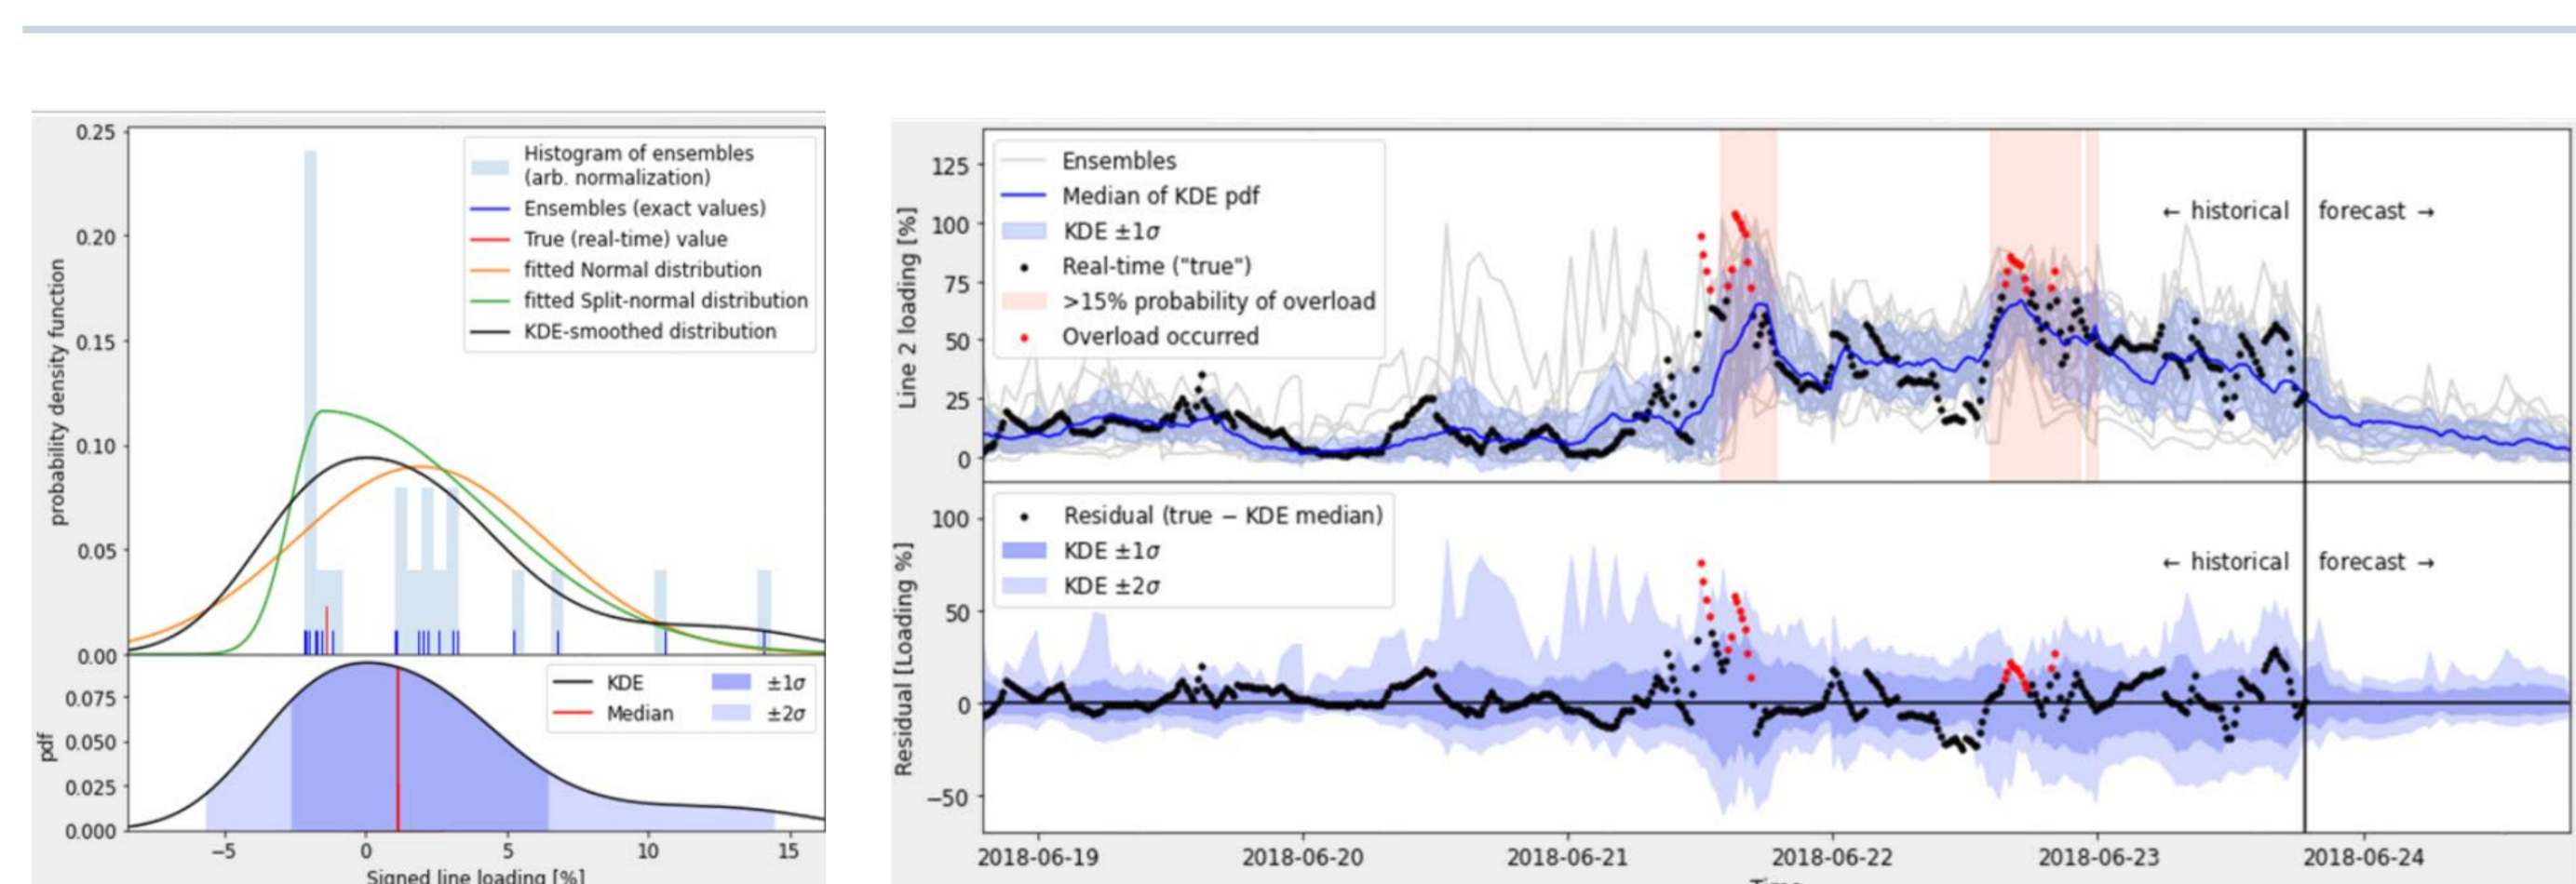
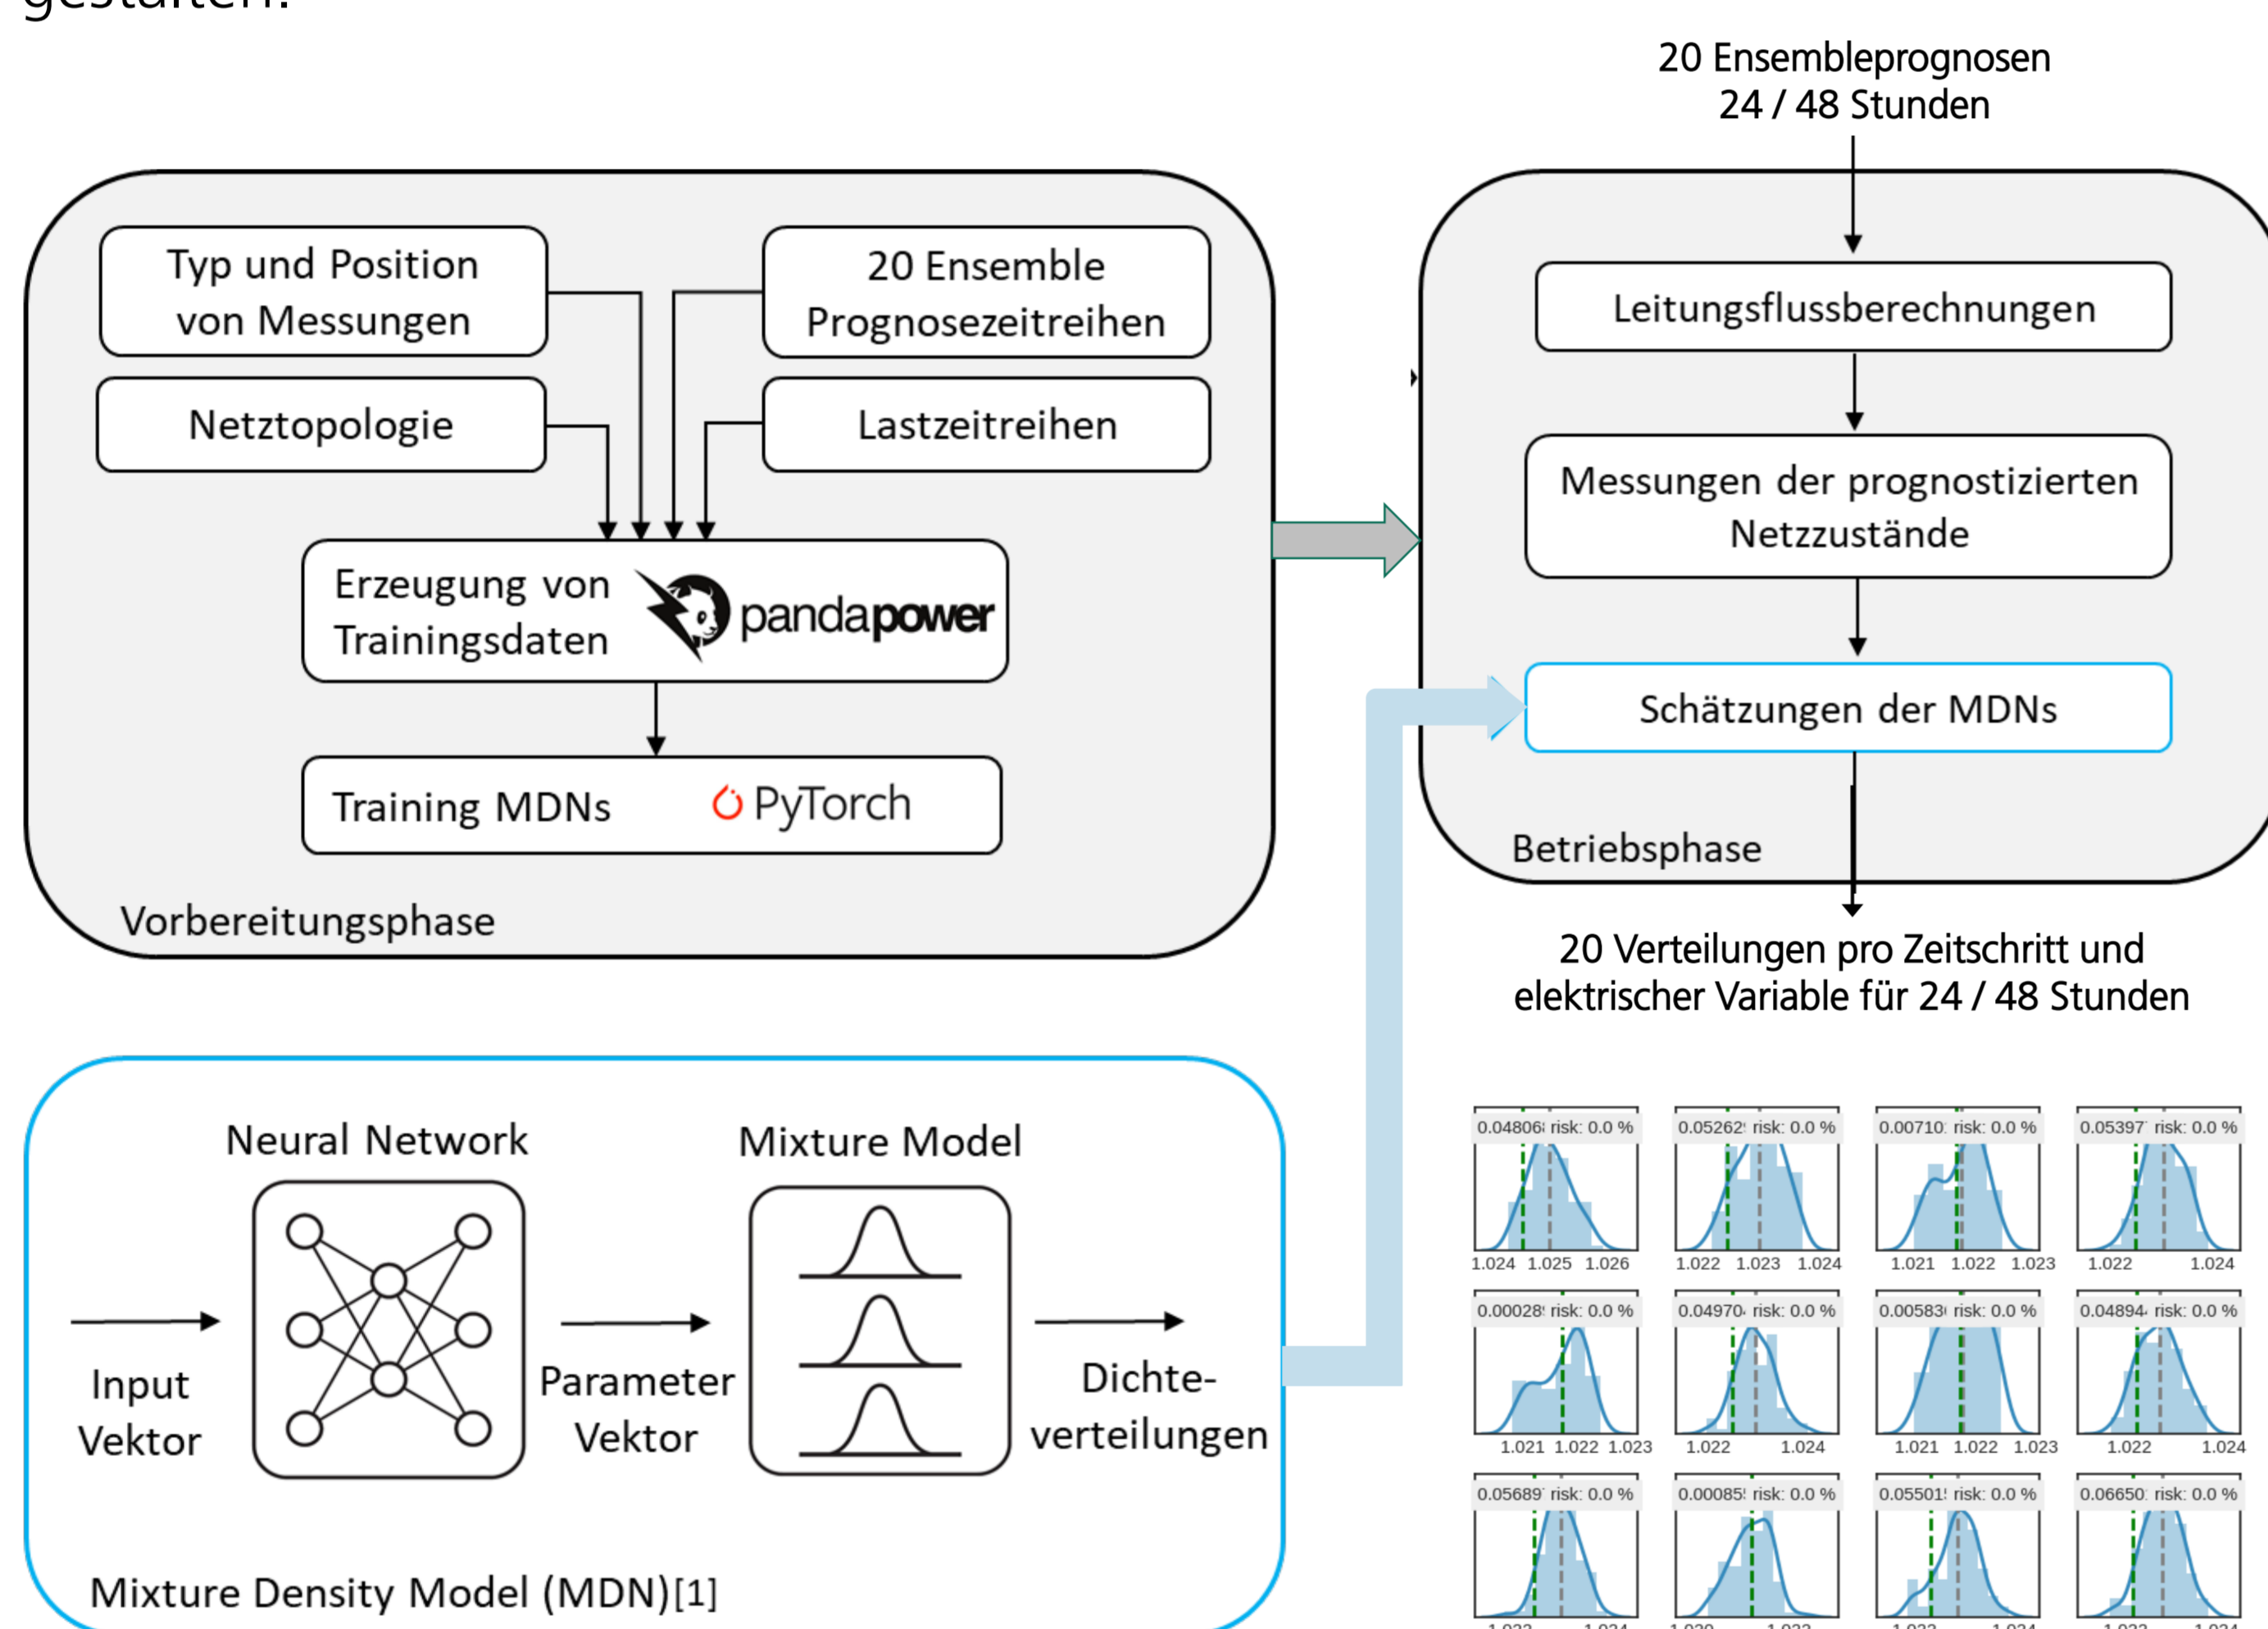


Abbildung 1: Der Weg von Ensembleprognosen über die Verarbeitung mit MDNs (obere Reihe) oder Glättungsfunktionen (untere Reihe) hin zu Netzzustandsverteilungen.

Umsetzung

In dem Projekt *Probabilistische Netzzustandsprognosen* wurden Ensembleprognosen, mithilfe von u.a. Multi-Density Networks und KDE Smoothing, zu Netzzustandsverteilungen verarbeitet. Diese werden dann über eine interaktive grafische Oberfläche dargestellt (siehe das [Video](#)).

NetzLupe – Optimierung auf Netzzustandsverteilungen

Optimierungsansätze

Um einen Mehrwert über das Wissen um diese Unsicherheiten bzw. Netzzustandsverteilungen zu erhalten, ist es nötig diese in Ansätzen zur Optimierung der Betriebsführung, wie das Engpassmanagement, mit einzubeziehen. In dem Projekt *NetzLupe* wurde mithilfe von Schalterstellungen anhand einer KI-basierten Optimierung versucht, Netzengpässe zu verringern bzw. zu vermeiden. Hierbei wurde ein selbstlernender Ansatz (Reinforcement Learning) gewählt, mit dessen Hilfe es möglich ist die Netzzustandsverteilung in die Optimierungsentscheidungen mit zu integrieren.

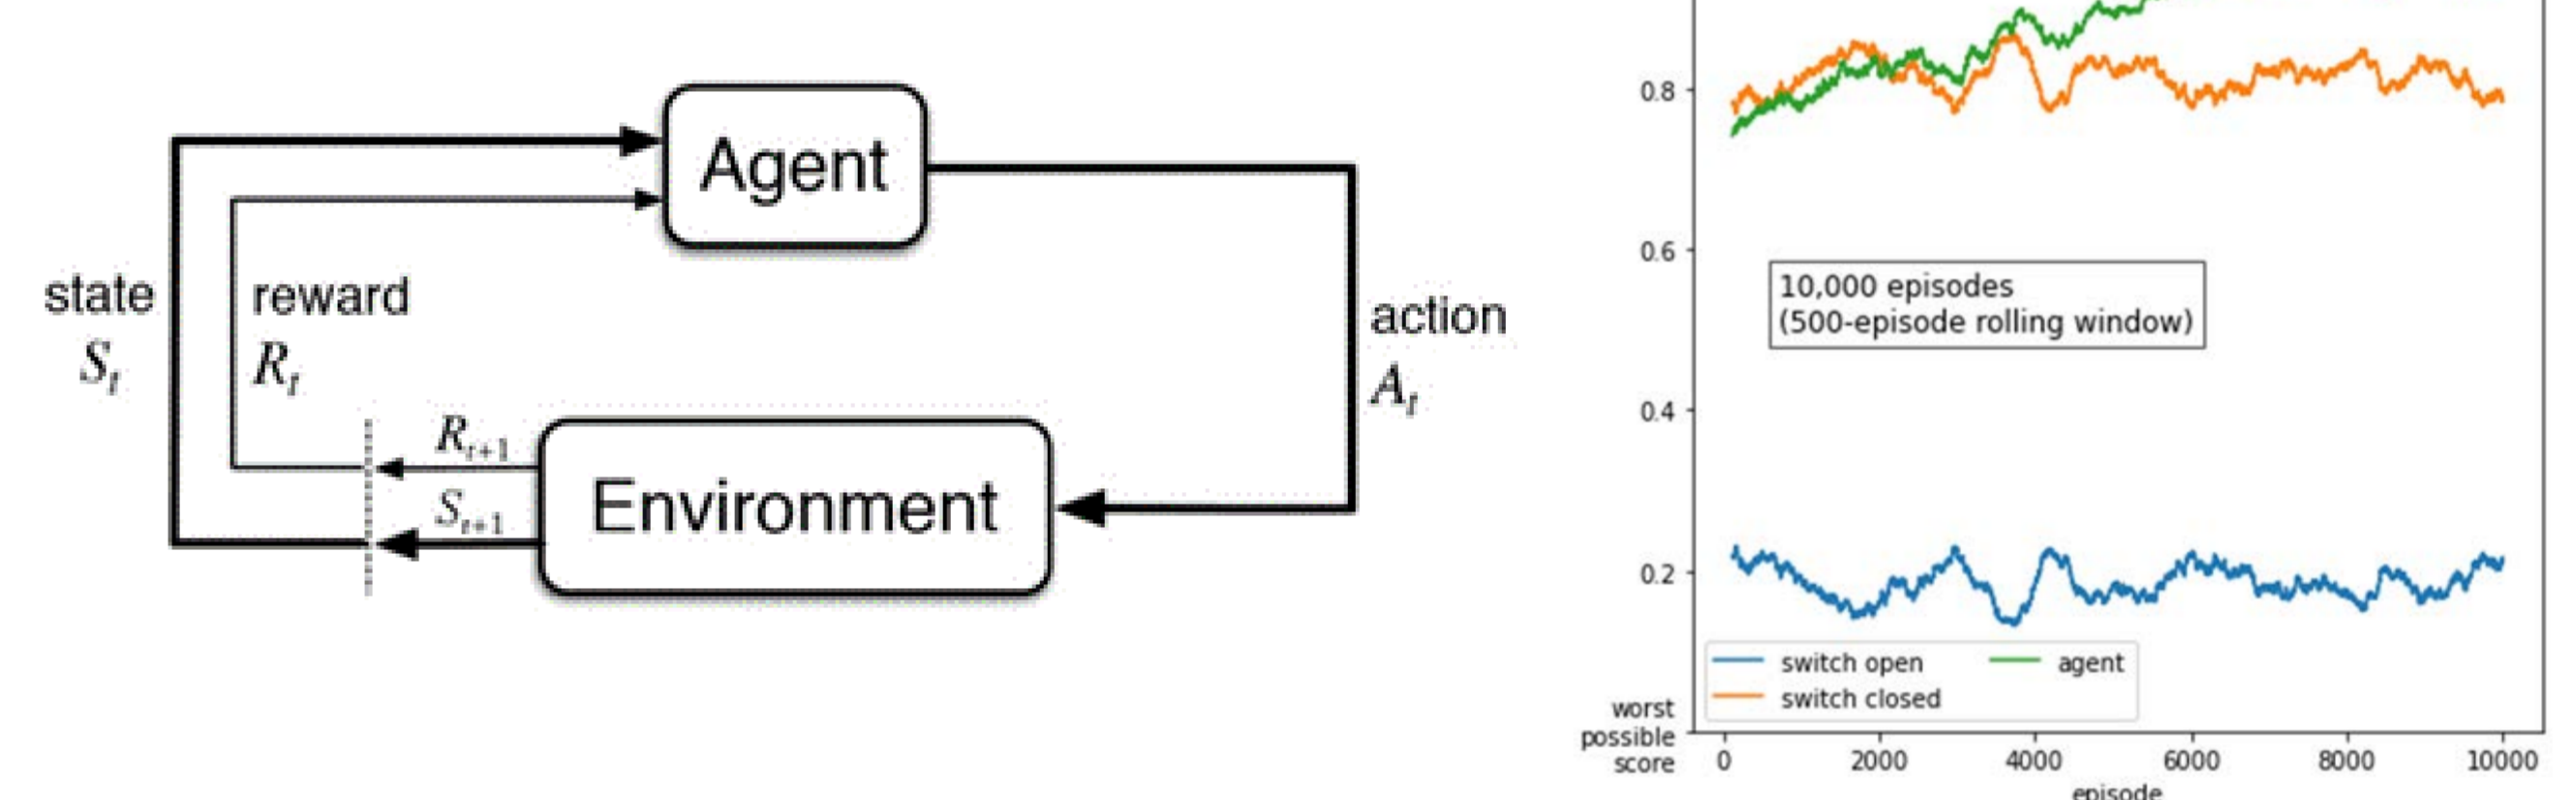


Abbildung 3: Links: Trainingsschema für selbstlernende Agenten. Rechts: Entwicklung des Agenten während der Trainingsperioden. Ab ca. 4000 Perioden zeigt der Agent durchweg bessere Ergebnisse als die konstanten Schalterstellungen »Auf« oder »Zu«.

Erste Ergebnisse

Es konnte gezeigt werden, dass Leitungsüberlastungen auf einfachen Netzen nur durch eine Rekonfiguration der Topologie verringert und sogar gelöst werden können. Hierbei wurde keine wertvolle Wirkleistung aus z.B. erneuerbaren Anlagen abgeregelt und somit konnte CO₂ an anderer Stelle eingespart werden.

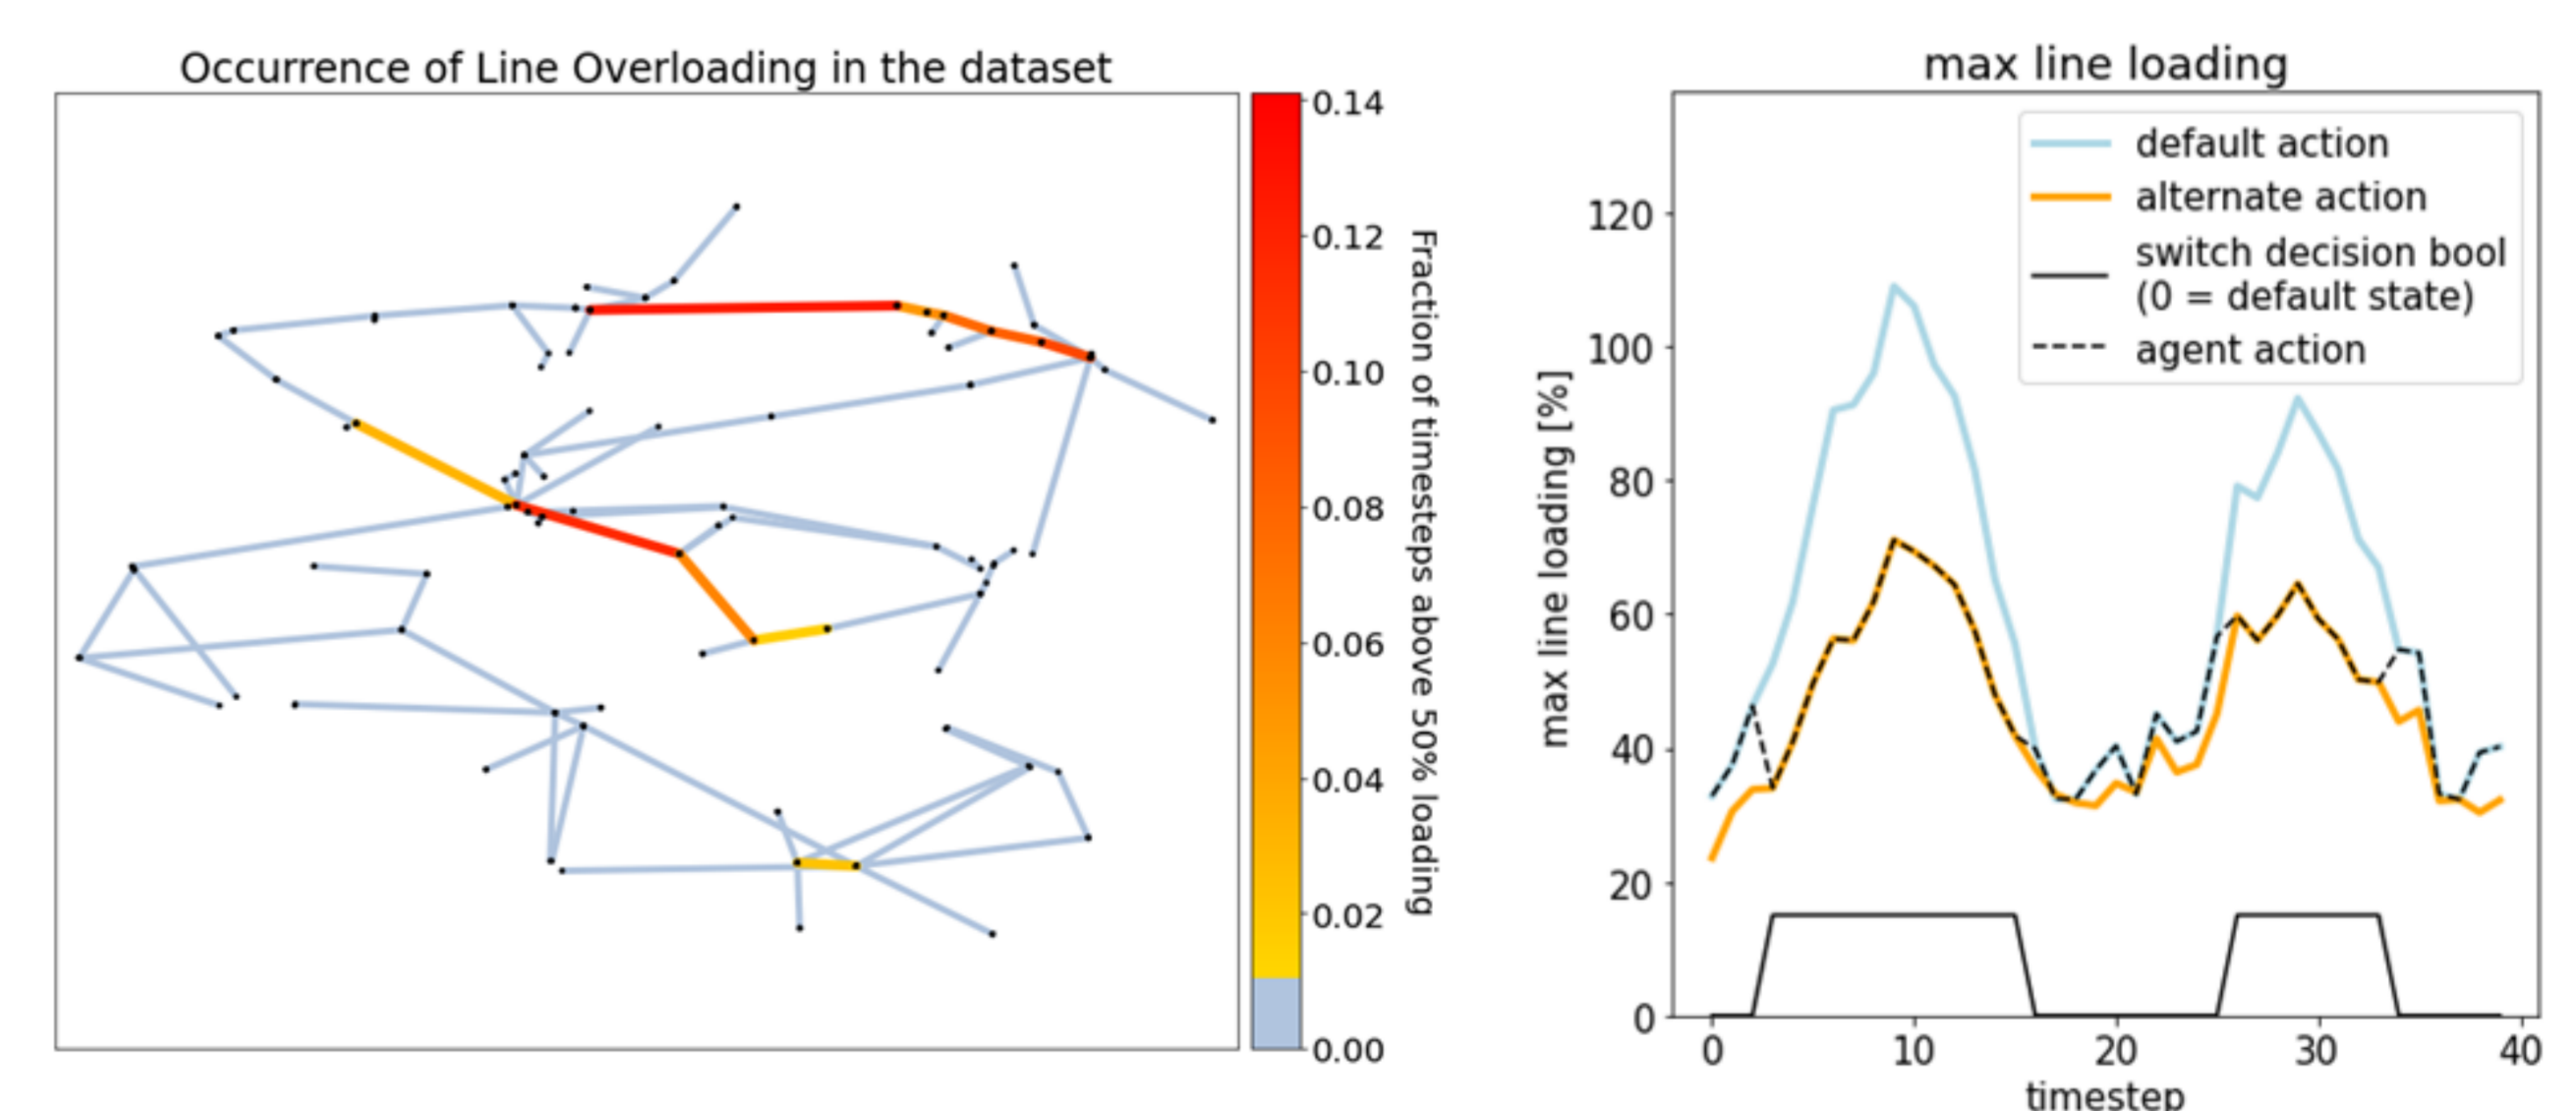


Abbildung 4: Links: Darstellung eines Testnetzes mit Leitungsüberlastungen. Rechts: Maximale Leitungsauslastung pro Zeitschritt einer Netzsimulation. Man sieht, dass der Agent durchwegs durch Schalthandlungen die Auslastung reduzieren kann.

Anwendung und Perspektiven

- Erkennen von alternativen Netzsituationen
- Bessere Einschätzung und Dimensionierung von Redispatchmaßnahmen
- Prädiktive Maßnahmenbestimmung um Netzengpässe im Vorfeld auszuschließen
- Optimierungsansätze um nur »bestimmte« Netzzustände zu realisieren
- Umsetzung der prototypischen Anwendung in eine operative Anwendung