

# Charakterisierung der Korrelationsstrukturen von stochastischen Zeitreihen für präzisere Energiesystemoptimierung unter Unsicherheit

EnInnov 2026 – Session A3 Energiesystemmodellierung III am 12.02.2026

**Klara Maggauer**<sup>(1,2)</sup>, Yannick Werner<sup>(2)</sup>, Stefan Strömer<sup>(1,3)</sup>, Sonja Wogrin<sup>(2)</sup>

1: AIT Austrian Institute of Technology GmbH

2: TU Graz/IEE

3: Delft University of Technology

# Förderhinweis

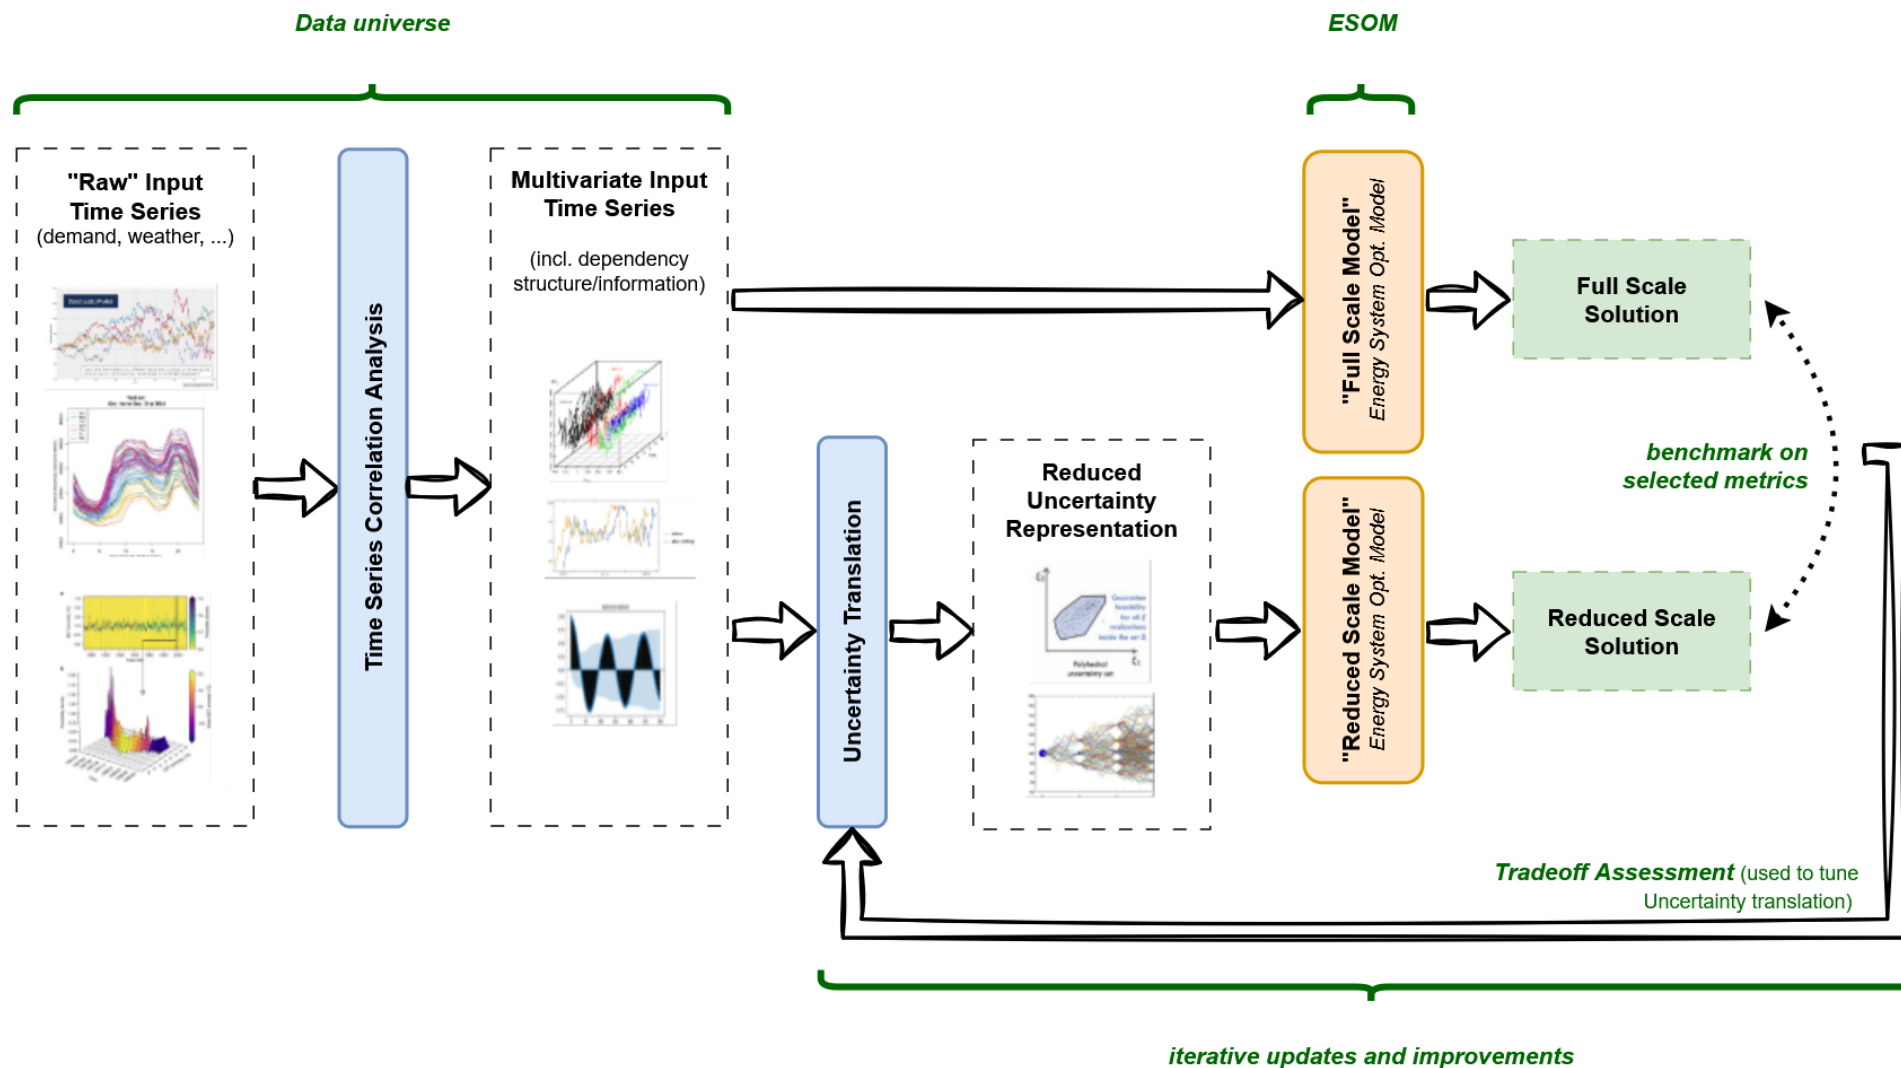
Dieses Projekt wird im Rahmen der Ausschreibung 2023 von „**AI for Green**“ des Bundesministeriums für Innovation, Mobilität und Infrastruktur (BMIMI) durchgeführt. Die Abwicklung erfolgt im Auftrag des BMIMI durch die Österreichische Forschungsförderungsgesellschaft (FFG). Das Projekt wird im Rahmen des Themas Digitale Technologien, eine Initiative des BMIMI, unter der Fördervertragsnummer FO999910239 gefördert. Die Autoren geben an, dass kein Interessenkonflikt besteht. Die Geldgeber spielten keine Rolle bei der Gestaltung der Studie; bei der Sammlung, Analyse oder Interpretation von Daten; beim Verfassen der Texte oder bei der Entscheidung, die Ergebnisse zu veröffentlichen.

# Motivation & Problemstellung

- ESOM\*-Inputs wie Stromerzeugung und Preise sind oft statistisch abhängig u.a. wegen wetter- und umweltabhängiger Energieerzeugung und dem Funktionsprinzip des Day-ahead-Strommarktes
- Statistische Abhängigkeiten in Zeitreihendaten zeigen sich bspw. als Korrelationen, Lag-Strukturen und Autokorrelation/Saisonalität
- In historischen Daten sind Abhängigkeiten automatisch enthalten
- **Problem:** Bei Szenariogenerierung, Zukunftsprojektionen oder aufgrund von Datenlücken gehen Abhängigkeiten leicht verloren
- **Folge:** Falsche Repräsentation des gemeinsamen Verhaltens dieser Variablen → Irreführende Optimierungsentscheidungen, da die „Realität“ nicht optimal wiedergegeben wird
- **Daher:** Abhängigkeiten sollten explizit modelliert werden (multivariat statt unabhängig)

\*ESOM=Energiesystemoptimierungsmodell

# The big picture...



# Inhalte & Ziele

- **Datentrio:** Solarerzeugung, Day-Ahead-Strompreise und Stromnachfrage in Österreich
- **Charakterisierung der Abhängigkeitsstruktur** mit linearen (Pearson) und rangbasierten Korrelationsmaßen für monotone und nichtlineare Zusammenhänge (Spearman)
- **Modellierung der Abhängigkeitsstruktur** mit einem copulabasierten Ansatz (Gauß- und Student-t-Copulas)
- **Ziel:** Untersuchung des Einflusses der Abhängigkeiten, indem Samples in zwei Varianten erzeugt und verglichen werden:
  - (i) statistisch unabhängige Stichproben (aus den Randverteilungen)
  - (ii) abhängigkeitserhaltende Stichproben (mit den Copulas)

# Datenbasis

- Österreichische Day-Ahead-Strompreise (EPEX), Stromnachfrage, Solar-Stromerzeugung von 1.1.2019 bis 31.12.2025 in 1h-Auflösung, CET/CEST\*
- Zerteilung in 7 Slices, jeweils 52 Wochen lang, beginnend mit Montag, endend mit Sonntag
- Analyse des Gesamt-Datensatzes (“pooled”) und der einzelnen Slices (ca. entsprechend der Kalenderjahre 2019-2025)


\*Quelle: [ENTSO-E Transparency Plattform](#) (2019-2022); [APG Markttransparenz](#) (2023-2025)

# Methode: Charakterisierung der Abhängigkeitsstruktur

- Pearson Korrelation für lineare Abhängigkeiten
  - Berechnung bei Lag 0 für relevante Variablenpaare (v.a. Last-Preis, Erzeugung-Preis)
  - Ergebnisse pooled und pro Jahr
  - Interpretation als lineares Co-Movement; dient als Baseline/Referenzmaß
- Rangbasiertes Korrelationsmaß (Spearman  $\rho$ ) für monotone und nichtlineare Zusammenhänge
  - Berechnung bei Lag 0 als robuste Alternative zu Pearson
  - Fokus auf monotone Abhängigkeiten (unempfindlicher gegenüber Ausreißern/Nicht-Normalität)
  - Ergebnisse pooled und pro Jahr

# Ergebnis: Charakterisierung der Abhängigkeitsstruktur

## PV Erzeugung vs. Day-ahead Preise



## Last vs. Day-ahead Preise




## Korrelationsmaße

- Pearson (r): lineare Korrelation (setzt v.a. linearen Zusammenhang voraus, ausreißer-empfindlicher).
- Spearman (ρ): rangbasierte Korrelation; misst monotone Zusammenhänge (auch nichtlinear, robuster gegen Ausreißer).

# Ergebnis: Charakterisierung der Abhängigkeitsstruktur

PV Erzeugung vs. Day-ahead Preise



Last vs. Day-ahead Preise

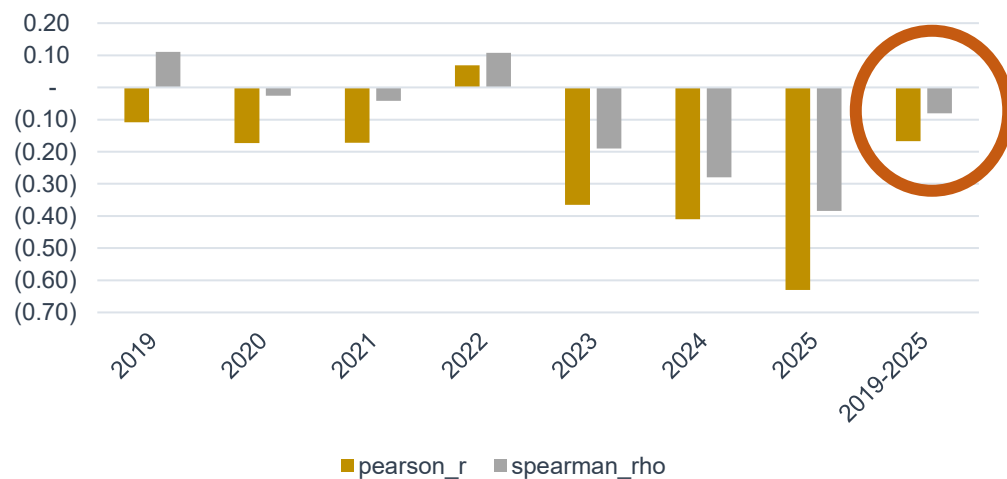


## Korrelationsmaße

- Pearson ( $r$ ): lineare Korrelation (setzt v.a. linearen Zusammenhang voraus, ausreißer-empfindlicher).
- Spearman ( $\rho$ ): rangbasierte Korrelation; misst monotone Zusammenhänge (auch nichtlinear, robuster gegen Ausreißer).

# Ergebnis: Charakterisierung der Abhängigkeitsstruktur

## PV Erzeugung vs. Day-ahead Preise



## Last vs. Day-ahead Preise



## Korrelationsmaße

- Pearson (r): lineare Korrelation (setzt v.a. linearen Zusammenhang voraus, ausreißer-empfindlicher).
- Spearman ( $\rho$ ): rangbasierte Korrelation; misst monotone Zusammenhänge (auch nichtlinear, robuster gegen Ausreißer).

# Interpretation: Charakterisierung der Abhängigkeitsstruktur

- **Last-Preis** zeigt durchgehend positive Korrelation, aber stark jahresabhängig:
  - 2019/2020 sehr stark (Pearson 0.67/0.60; Spearman 0.70/0.64) → „hohe Last ↔ hohe Preise“
  - 2021 deutlich schwächer (0.39/0.29) und 2022 am schwächsten (0.18/0.22) → Hinweis auf Sonderregime wegen Energiekrise
  - 2023-2025 wieder klar stärkere Korrelation (0.58-0.55)
- **Solar-Preis:** Trend zu immer stärker negativer Abhängigkeit ab 2023:
  - 2019-2021 nur schwache/uneinheitliche Korrelation (Pearson  $\sim$ -0.11 bis -0.17; Spearman nahe 0 bzw. leicht negativ/teils positiv)
  - 2022 sogar leicht positiv (0.07 / 0.11) → erneut Hinweis auf Sonderregime wegen Energiekrise
  - 2023-2025 klar negativ und zunehmend stark (Pearson -0.37 → -0.63; Spearman -0.19 → -0.38) → konsistent mit steigender PV-Penetration und dadurch größerer Auswirkungen auf die Merit-Order
- **Pearson vs. Spearman:**
  - Spearman bestätigt die Richtung als monotone Beziehung, oft etwas geringer (v.a. bei Solar), was auf Nichtlinearität/saisonale Effekte hindeutet (z.B. Preis-Kollaps nur bei sehr hoher Solarproduktion; keine Solarproduktion in der Nacht)
- **Pooled (2019-2025)** ist deutlich kleiner als die Jahreswerte:
  - Load-Preis sinkt auf 0.22/0.26, obwohl viele Jahre Korrelationen von 0.5-0.7 zeigen
  - Solar-Preis bleibt moderat negativ (-0.17/-0.08) → Pooling verwässert Nicht-Stationarität (v.a. wegen PV-Ausbau), daher sind jahresweise Ergebnisse für Interpretation wichtig

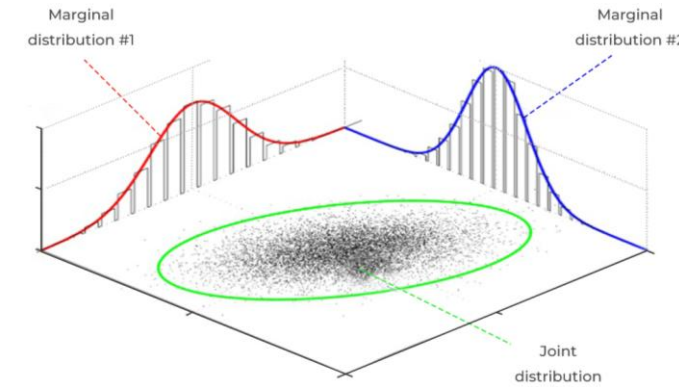
# Methode: Erstellung der Randverteilungen und Copulas

## 1. Schätzung der Randverteilungen pro Variable

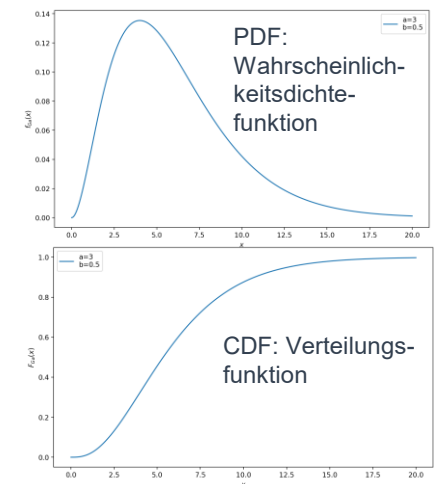
- Sammlung und Sortierung aller Werte für jede Variable (Preis, Last, Erzeugung)
- Daraus Ableitung einer empirischen CDF:  $F(x)=\Pr(X \leq x)$ ; beschreibt die Wahrscheinlichkeit, dass  $X$  einen Wert kleiner oder gleich  $x$  annimmt
- Zusätzlich Erstellung der empirischen Inverse-CDF  $F^{-1}(u)$  als Quantilfunktion (Interpolation auf den sortierten Werten), um Uniformwerte wieder in echte Werte zurückübersetzen zu können

## 2. Probability Integral Transform (PIT): Transformation in $\mathbf{U}(0,1)$

- Für jeden Zeitpunkt  $t$  und jede Variable wurde aus dem Originalwert  $X_t$  ein Prozentwert gemacht:  $U_t=F(X_t)$ ;  $U_t \in (0,1)$
- Damit liegen alle Variablen im selben Standardraum:  $\mathbf{U}(0,1)$  (jeweils relativ zu ihrer eigenen Verteilung)
- Für die Szenarienziehung wird der Inverse-Transform-Algorithmus genutzt:  $X=F^{-1}(U)$ , also Transformation der Uniformwerte zurück auf echte Werte, mit der empirischen Inverse-CDF  $F^{-1}$



Quelle: <https://analystprep.com/study-notes/wp-content/uploads/2019/04/page-132.jpg> (01.02.2026, 13:04)




# Methode: Erstellung der Randverteilungen und Copulas

## 3. Auswahl und Fitting der Copulas: Modellierung der Abhängigkeitsstruktur auf den transformierten Daten U

- Gauß Copula: Überführung von U in den Normalraum über  $Z = \Phi^{-1}(U)$  (z-Score der Normalverteilung) und daraus Schätzung einer Korrelationsmatrix (entspricht dem Abhängigkeitsparameter)
- Student-t Copula: Analog, aber mit t-Verteilung; zusätzlich Schätzung der Parameter df („degrees of freedom“; Freiheitsgrade), der gemeinsame Extremereignisse („Tail-Abhängigkeit“) abbilden kann.
- Beide Fits wurden pooled (und je nach Setup auch slice-weise) durchgeführt, um stabile Parameter zu erhalten bzw. Nichtstationarität zu prüfen

## 4. Schätzung folgender Parameter:

- Korrelationsmatrizen (Gaussian/t-Copula)
- Freiheitsgrade df (t-Copula)




# Methode: Untersuchung des Einflusses der Abhängigkeiten

- Ziehung von 50 000 Stichproben:
  - (i) Unabhängige Samples aus den jeweiligen Randverteilungen
  - (ii) Abhängigkeits-erhaltend: Aus den Copulas
- Vergleich: Berechnung von Korrelationsmaßen in beiden Stichproben → Quantifizierung des Einflusses der Abhängigkeit

# Ergebnis: Einfluss der Abhängigkeiten



## Last vs. Day-ahead Preise



- **Unabhängige Szenarien** liefern auch hier Korrelationen ca. 0
- **Copula-Szenarien** (t und Gauß) reproduzieren positive Last-Preis Abhängigkeit gut und liegen nahe an den Daten (bei Spearman etwas näher)
- **Pooled 2019-2025**: Schwächere Korrelation als 2025 → Hinweis darauf, dass die Korrelation sich über die Jahre verändert hat
- **Student-t ≈ Gauß**: sehr ähnliche Balken → Hinweis auf wenig Tail-Dependence

# Ergebnis: Einfluss der Abhängigkeiten

## PV vs. Day-ahead Preise



- **Unabhängig gezogene Szenarien** eliminieren die Abhängigkeit → Korrelationen ca. 0
- **Copula-Szenarien** erhalten die negative PV-Preis Abhängigkeit und sind deutlich näher an den Daten als die unabh. Samples
- **Pooled 2019-2025** Zusammenhang insgesamt nur moderat negativ → Pooling glättet unterschiedliche Jahre
- **2025:** Daten zeigen sehr starke negative Korrelation; Copulas bilden das qualitativ ab, unterschätzen aber die Stärke (v. a. Pearson) → Hinweis auf Nichtlinearität/Saisonalität, die elliptische Copulas nur begrenzt wiedergeben können
- **Student-t ≈ Gauß:** Kaum Unterschied in Pearson/Spearman → Hinweis auf wenig Tail-Dependence

# Conclusio

- **Deutliche Abhängigkeiten** zw. den betrachteten Parametern, die modelliert werden sollten:
  - Korrelationsanalyse der Daten zeigt klar Abhängigkeiten, daher wissen wir, dass Copulas nötig sind
  - iid-Sampling eliminiert Abhängigkeiten (Korrelation ca. 0)
  - Im qualitativen Vergleich sieht man, dass die mit Copulas erzeugten Samples die Korrelation gut erhalten
- **Abhängigkeitsstruktur** ist eindeutig **jahresabhängig**:
  - Besonders Solar-Preis wird ab 2023 zunehmend stark negativ (PV-Penetration/Merit-Order-Effekt)
  - Die Energiekrise ist deutlich als Sonderfall erkennbar
- **Pooling (2019-2025) verwässert zentrale Effekte**, d.h. für Interpretation und Szenarien sind jahres-spezifische Analysen wichtig
- **Elliptische Copulas treffen die zentralen Trends**, aber nicht alle Details: Hinweis auf Nichtlinearität/Saisonalität
- **Student-t  $\approx$  Gauß Copula**: Kaum Unterschiede in Pearson/Spearman erkennbar  $\rightarrow$  wenig Evidenz für starke Tail-Dependence (zumindest gemessen über Korrelationen)

# Limitationen & Ausblick auf nächste Schritte

- **Modellierung der zeitlichen Abhängigkeit:**
  - Bisher wurde nur die gleichzeitige Abhängigkeitsstruktur abgebildet → Auto- und Cross-Korrelation fehlt
  - Modellierung möglich durch zeitvariable Copulas, z.B. GARCH (Generalized Autoregressive Conditional Heteroskedasticity)-basierte Copula-Modelle oder generell dynamische Copulas
- **Saisonalität expliziter behandeln:** Abhängigkeiten werden durch Tages-/ Wochenmuster beeinflusst → Analyse auf Residuals (de-seasonalized) oder konditioniert (z. B. daytime-only / hour-of-day)
- **Nichtlinearität besser modellieren:** Bisher Fokus auf elliptische Copulas → mögliche Erweiterungen: Vine-Copulas, regime-switching Copulas, oder Copulas pro Zeitfenster/Saison
- **Tail-Dependence gezielt prüfen** (nicht nur über Korrelationen) z. B. gemeinsame Extremereignisse näher analysieren
- **Robustheit über Jahre/Systemzustände:**
  - Separate Fits für Normaljahre vs. Krisenjahr 2022 und für unterschiedliche RES-Ausbaustände
  - Nutzung von Capacity Factors statt expliziter Erzeugung

# Quellen

- [1] M. Haugen, H. Farahmand, S. Jaehnert, and S.-E. Fleten, “Representation of uncertainty in market models for operational planning and forecasting in renewable power systems: a review,” *Energy Syst*, Jul. 2023, doi: 10.1007/s12667-023-00600-4.
- [2] A. R. Jordehi, “How to deal with uncertainties in electric power systems? A review,” *Renewable and Sustainable Energy Reviews*, vol. 96, pp. 145–155, Nov. 2018, doi: 10.1016/j.rser.2018.07.056.
- [3] K. N. Hasan, R. Preece, and J. V. Milanović, “Existing approaches and trends in uncertainty modelling and probabilistic stability analysis of power systems with renewable generation,” *Renewable and Sustainable Energy Reviews*, vol. 101, pp. 168–180, Mar. 2019, doi: 10.1016/j.rser.2018.10.027.
- [4] L. S. Plaga and V. Bertsch, “Methods for assessing climate uncertainty in energy system models — A systematic literature review,” *Applied Energy*, vol. 331, p. 120384, Feb. 2023, doi: 10.1016/j.apenergy.2022.120384.
- [5] A. Shemyakin and A. Kniazev, *Introduction to Bayesian Estimation and Copula Models of Dependence*. John Wiley & Sons, 2017, doi: 10.1002/9781118959046.
- [6] N. Veyrat-Charvillon and F.-X. Standaert, “Mutual Information Analysis: How, When and Why?,” in *Cryptographic Hardware and Embedded Systems - CHES 2009*, C. Clavier and K. Gaj, Eds., Berlin, Heidelberg: Springer, 2009, pp. 429–443. doi: 10.1007/978-3-642-04138-9\_30.
- [7] A. J. Patton, “A review of copula models for economic time series,” *Journal of Multivariate Analysis*, vol. 110, pp. 4–18, Sep. 2012, doi: 10.1016/j.jmva.2012.02.021.
- [8] H. Joe, *Dependence Modeling with Copulas*. CRC Press, 2014, doi: 10.1201/b17116.
- Seabold, Skipper, and Josef Perktold. “statsmodels: Econometric and statistical modeling with python.” Proceedings of the 9th Python in Science Conference. 2010.
- Pauli Virtanen et al. (2020) SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. *Nature Methods*, 17(3), 261-272. DOI: 10.1038/s41592-019-0686-2

# Charakterisierung der Korrelationsstrukturen von stochastischen Zeitreihen für präzisere Energiesystemoptimierung unter Unsicherheit


EnInnov 2026 – Session A3 Energiesystemmodellierung III am 12.02.2026

Danke für die Aufmerksamkeit.

**Klara Maggauer**  
Research Engineer  
Integrated Energy Systems  
Center for Energy

**AIT Austrian Institute of Technology GmbH**  
Giefinggasse 6 | 1210 Vienna | Austria  
M +43 664 7858 8129  
[klara.maggauer@ait.ac.at](mailto:klara.maggauer@ait.ac.at) | [www.ait.ac.at](http://www.ait.ac.at)



 Bundesministerium  
Innovation, Mobilität  
und Infrastruktur

AI for Green – Ausschreibung 2023

# transpAIrent.energy

## Transparent AI Forecasts for Green Energy in Austria

### Project goals:

- Development of an innovative generative AI-based algorithm for creating probabilistic forecasts for variables relevant to the energy system and publishing them live on a transparent platform
- Using these forecasts to optimize flexible renewable energy systems to make their operation both more economical and more sustainable

### Project contents:

- Data collection, processing, and documentation as well as the creation of weather forecasts (WP2)
- Development of AI-based forecasting algorithms (WP3)
- Platform development and implementation (WP4)
- Method validation (“proof of concept”) through simulation and live testing (WP5)

### Key facts about the project:

- Duration: 01.05.2024 – 30.04.2027 (36 months)
- Consortium:
  - AIT Austrian Institute of Technology GmbH (RTO)
  - B-SEC better secure GmbH & Co KG (IT company)
  - pbeg Projektplanungs- Beratungs- und Entwicklungs GmbH (Planner for renewable energy assets)
  - UBIMET GmbH (Meteorological services provider)
- Project lead: Klara Maggauer, M. Sc. (AIT)  
[klara.maggauer@ait.ac.at](mailto:klara.maggauer@ait.ac.at) | <https://www.ait.ac.at/en/research-topics/flexibility-business-models/projects/transpairentenergy>
- Project websites:  
<https://projekte.ffg.at/projekt/5121370> |  
<https://en.ergie.at/projekte/transpairent-energy/>