

Ankündigung für WS 2022/2023

Seminar (0174200)

Angewandt Mathematisches Seminar Applied Mathematical Seminar

Ab 5. Sem.: Mathematik, Technomathematik, Wirtschaftsmathematik

Hinweis

Bei Interesse an einem Thema kann ich schon Material dazu zur Verfügung stellen. Diese Artikel stellen das Thema dar, sind aber meist viel umfangreicher als es inhaltlich für das Seminar verlangt werden kann. Erst im Gespräch wird geklärt, was wirklich geleistet werden soll.

Bei sehr konkreten fokussierten Interessen ist eine Ausweitung des Angebotes möglich.

English talks are welcome, most of the underlying papers are in English.

Vortragsangebot

* Grundlagen

- (A) **Summierungsmethode.** Neuartige Verbesserung der Euler–Maclaurin Summation zur Berechnung langreichweitiger Potentiale. Darüber wurde sogar im Spektrum der Wissenschaft berichtet (Heft 8/22) [Buchheit et al, 2021] <https://link.springer.com/content/pdf/10.1007/s10915-021-01731-5.pdf> **Ab 6. Sem.**

* Adaptive Fehlerschätzung

- (B) **Zeitschrittweitensteuerung bei gewöhnlichen Differentialgleichungen.**

- (a) Adaptive Steuerung bei Differentialgleichungen [Deuffhard/Bornemann *Numerische Mathematik II*, Kap. 5.1–5.3].
- (b) Dynamische Elimination schneller Freiheitsgrade [Deuffhard/Bornemann *Numerische Mathematik II*, Kap. 6.4.3].
- (c) Zeitschrittweitensteuerung bei Mehrschrittverfahren zur Lösung gewöhnlicher Differentialgleichungen [Deuffhard/Bornemann *Numerische Mathematik II*, Kap. 7.4.1–7.4.2].

Ab 6. Sem.

- (C) **Adaptive Finite Elemente Methoden.** Für das Poisson-Problem lässt sich der Fehler der Finite-Elemente-Methode mittels der erhaltenen numerischen Lösung abschätzen. Allerdings wird der Einfluß des Fehlers in der Approximation der Daten nur grob wiedergegeben. Die Arbeit gibt dazu eine genauere Analyse. [Kreuzer/Veeser 2019] <https://link.springer.com/article/10.1007/s00211-021-01194-8>

*** Batterie**

- (D) **Cahn–Hilliard-Gleichung mit Elastizität.** Die Cahn–Hilliard-Gleichung beschreibt den Phasenübergang im aktiven Material beim Lade- und Entladeprozess einer Batterie. Bei diesem Phasenübergang ändern sich auch mechanische Eigenschaften und dies führt zu einer Volumenänderung des Körpers. Hier werden die Gleichung mit linearer Elastizität gekoppelt (in realistischen Situationen (Lithium!) benötigt man aber große Verformungen). [Garcke et al (2001)] <https://ems.press/content/serial-article-files/83>
- (E) **Adaptive Steuerung der Cahn–Hilliard-Gleichung.** Die Cahn–Hilliard-Gleichung beschreibt den Phasenübergang im aktiven Material beim Lade- und Entladeprozess. Die zeit- und ortsabhängige partielle Differentialgleichung soll mit adaptiver Steuerung der Orts- und Zeitschritte gelöst werden, inklusive einer Abschätzung des Gesamtfehlers. [Bartels, Müller (2010)] <https://link.springer.com/content/pdf/10.1007/s00211-011-0389-9.pdf>

*** Optimale Kontrolle / Neuronale Netze**

- (F) **Physics-Informed Neural Networks I (PINN).** Lösung von Partiellen Differentialgleichungen (aus der mathematischen Physik) mittels Neuronaler Netze. [Karniadakis et al 1 (2018)] <https://www.sciencedirect.com/science/article/pii/S0021999118307125>
- (G) **Physics-Informed Neural Networks II (PINN).** Konvergenz von PINN für elliptische/parabolische Probleme. [Karniadakis et al 2 (2018)] <https://arxiv.org/pdf/2004.01806.pdf>
- (H) **Physics-Informed Neural Networks III (PINN).** Anwendung von PINN auf die Allen–Cahn oder Cahn–Hilliard Gleichungen. [Ghosh et al 2022] https://www.researchgate.net/profile/Revanth-Mattey/publication/357600018_A_novel_sequential_method_to_train_physics_informed_neural_networks_for_Allen_Cahn_and_Cahn_Hilliard_equations/links/61e58b239a753545e2d97e9c/A-novel-sequential-method-to-train-physics-informed-neural.pdf
- (I) **DeepONet.** Das Lernen von Lösungen beruht auf der Approximierbarkeit stetiger Funktionen durch Neuronale Netze. Die Sichtweise wird hier auf die Approximierbarkeit von Differentialoperatoren erweitert [Karniadakis et al 3 (2020)] <https://arxiv.org/pdf/1910.03193.pdf>
- (J) **Deep Learning als Optimale-Kontrolle-Problem.** Interpretation von Deep Learning als Diskretisierung eines Optimal Control Problems für Differentialgleichungen. [Benning et al (2019)] <https://arxiv.org/pdf/1904.05657.pdf> **Ab 6. Sem.**

*** Magnetisierung**

- (K) **Landau–Lifschitz–Gilbert-Gleichungen.** Die Landau–Lifschitz–Gilbert-Gleichungen modellieren den Schreibvorgang in einem Magnetspeicher. Hier wird eine Finite-Elemente-Diskretisierung diskutiert. [Alouges (2007)] <https://www.aims sciences.org/article/exportPdf?id=df320bac-5378-409c-aec5-06efe621e191>

*** Raum-Zeit-Diskretisierungen**

- (L) **Paralleles Raum-Zeit-Verfahren.** Analyse einer Raum-Zeit parallelen Diskretisierung einer parabolischen Gleichung. [Neumüller, Smears (2018)] <https://epubs.siam.org/doi/pdf/10.1137/18M1172466>

*** Softwaretests von frei verfügbaren Softwarepaketen**

- (M) **DUNE PDE Lab.** Programmpaket zur Lösung von partiellen Differentialgleichungen in C++ <https://www.dune-project.org/>. Ziel ist die Installation des Paketes (am besten in Linux) und das Lösen ausgewählter Randwertprobleme.
- (N) **PyMOR.** Model Order Reduction with Python [Rave et al (2016), <https://pymor.org/>]. Die Anwendung ist die wiederholte Berechnung eines Randwertproblem bei sich ändernden Materialparametern.

*** Wellen**

- (O) **Perfectly matched layers.** Konstruktion und Analyse einer Randbedingung für auslaufende Wellen bei der Wellengleichung. [Chern (2019)] <https://arxiv.org/pdf/1804.01390.pdf>
- (P) **Complex scaled infinite elements.** Konstruktion und Analyse einer Randbedingung für auslaufende Wellen bei der Helmholtzgleichung. [Nannen et al (2019)] <https://arxiv.org/pdf/1907.09746.pdf>