

Modulhandbuch

für den Studiengang

Data Science (B.Sc.)

Sommersemester 2021

Hinweise:

- Weitere Informationen zu den einzelnen Studiengängen (Studien- und Prüfungsordnungen, Studienberatung, etc.) finden Sie auf www.math.fau.de/studium
- Semesteraktuelle Informationen zu den angebotenen Lehrveranstaltungen finden Sie im UnivIS-Vorlesungsverzeichnis.
- Module eines Studiengangs sind in der jeweiligen Prüfungsordnung festgelegt. Diese Sammlung umfasst die Module, die vom Department Mathematik in den jeweiligen Studiengängen verwendet werden.

Inhaltsverzeichnis

- Modul EmDA: Einführung in die mathematische Datenanalyse..... 4
- Modul MDS 2: Mathematik für Data Science 2 6
- Modul MP-B: Mathematik für Physikstudierende B..... 8
- Modul MFDL: Mathematische Forschung zu Deep Learning..... 10

1	Modulbezeichnung	Modul EmDA: Einführung in die mathematische Datenanalyse (englische Übersetzung: Introduction in Mathematical Data Analysis)	ECTS 5
2	Lehrveranstaltungen	Vorlesung zur Einführung in die mathematische Datenanalyse (V) - 2 SWS Übung zur Einführung in die mathematische Datenanalyse (Ü)- 1 SWS	
3	Lehrende	Dr. Philipp Wacker wacker@math.fau.de	
4	Modulverantwortung	Prof. Dr. Martin Burger martin.burger@fau.de	
5	Inhalt	<ul style="list-style-type: none"> - fortgeschrittene Inhalte zu Eigenwerten, - Hauptachsentransformation, - Singulärwertzerlegung -> Principal Component Analysis, - Spectral Clustering - Optimierung: <ul style="list-style-type: none"> - Vertiefung zu Extremwerten, - Extrema mit Nebenbedingungen, - Sätze über implizite und inverse Funktionen. - Vertiefung von Gradienten etc. -> Lernverfahren, stochastische Gradientenverfahren - lineare Differentialoperatoren (Gradient, Divergenz, Rotation) - Kurvenintegrale, - Vektorfelder, <p>Integralsätze von Gauß und Stokes (ggf. ohne detaillierte Beweise)</p>	
6	Lernziele und Kompetenzen	<p>Die Studierenden</p> <ul style="list-style-type: none"> - können fortgeschrittene Inhalte zu Eigenwerten, Hauptachsentransformation, Singulärwertzerlegung (Principal Component Analysis) und Spectral Clustering erklären - verstehen die Anwendung von Extremwerten und Gradienten in der Optimierung und in Optimierungsverfahren <p>kennen Kurvenintegrale, Vektorfelder, Integralsätze von Gauß und Stokes</p>	
7	Voraussetzungen für die Teilnahme		
8	Einpassung in Musterstudienplan	2. Semester	
9	Verwendbarkeit des Moduls	Pflichtmodul in: B. Sc. Data Sciences (Kernmodul)	
10	Studien- und Prüfungsleistung	Klausur (60 Min.)	
11	Berechnung Modulnote	Klausur (100 %)	
12	Turnus des Angebots	1 x jährlich jeweils im SoSe	
13	Arbeitsaufwand	<p>Workload 150h davon: Vorlesung: 2 SWS x 15 = 30 h Übung: 1 SWS x 15 = 15h Eigenstudium: 105 h</p>	

14	Dauer des Moduls	1 Semester
15	Unterrichts- und Prüfungssprache	deutsch
16	Literaturhinweise	

1	Modulbezeichnung	Modul MDS 2: Mathematik für Data Science 2 (Best of Lineare Algebra II und Analysis II)	ECTS 10
2	Lehrveranstaltungen	Vorlesung Übung Tafelübung	
3	Lehrende	Dr. Daniel Tenbrinck daniel.tenbrinck@fau.de	
4	Modulverantwortung	Prof. Dr. Frauke Liers frauke.liers@math.uni-erlangen.de	
5	Inhalt	<ul style="list-style-type: none"> • Eigenwerte • Euklidische Vektorräume (Orthonormalisierung, Orthogonalprojektion). • Diskrete Fouriertransformation als Beispiel für Orthogonalbasis, Hinführung auf Fourier-Reihen • Normierte Räume, stetige Abbildungen zwischen normierten Räumen, Kompaktheit, Vollständigkeit, Dualraum • Fixpunktsatz von Banach • Satz von Arzela-Ascoli (kurz) • Bilinearformen, Skalarprodukte • Adjungierte Operatoren • Differentialrechnung in mehreren Veränderlichen: Partielle Ableitung und Jacobi-Matrix, Satz von Schwarz, • Grundlagen Lineare Differentialgleichungen mit konstanten Koeffizienten: Lösung mittels Exponentiation von Matrizen bzw. mit charakteristischem Polynom • Gewöhnliche Differentialgleichungen: Lokale und globale Existenz und Eindeutigkeit der Lösung, Phasenportrait (DGL: insgesamt 2 Wochen) • Extrema, Optimierung mit Nebenbedingungen (kurz, wird im Kernmodul vertieft) • totale Ableitung und Linearisierung, Lipschitz-Stetigkeit und Schrankensatz, Taylorformel (ggf. mit wenig Beweisen) 	
6	Lernziele und Kompetenzen	<p>Die Studierenden</p> <ul style="list-style-type: none"> • erweitern ihr Spektrum an Grundbegriffen der Analysis und erklären diese; • wenden das Grundwissen der Analysis an, reproduzieren und vertiefen grundlegende Prinzipien und ordnen diese ein; • wenden Grundtechniken der Analysis an; • sammeln und bewerten relevante Informationen und erkennen Zusammenhänge, erkennen lineare und nichtlineare Zusammenhänge und behandeln sie quantitativ und qualitativ; • verwenden und untersuchen quadratische Formen als die einfachsten nicht-linearen Funktionen; • verwenden Dualräume zur Analyse linearer Abbildungen; • erkennen die Querverbindung zur Analysis; • führen exemplarische inner- und außermathematische Anwendungen durch. 	
7	Voraussetzungen für die Teilnahme	empfohlen: Mathematik für Data Science 1	
8	Einpassung in Musterstudienplan	2. Semester	
9	Verwendbarkeit des Moduls	Pflichtmodul: B. Sc. Data Sciences (Grundlagenmodul)	

10	Studien- und Prüfungsleistung	Übungsleistung (unbenotet) Klausur (90 min)
11	Berechnung Modulnote	Klausur (100 %)
12	Turnus des Angebots	1 x jährlich jeweils SoSe
13	Arbeitsaufwand	Workload 150h davon: Vorlesung: 4 SWS x 15 = 60 h Übung: 2 SWS x 15 = 30h Tafelübung: 2 SWS x 15 = 30h Eigenstudium: 30 h
14	Dauer des Moduls	1 Semester
15	Unterrichts- und Prüfungssprache	deutsch
16	Literaturhinweise	

1	Modulbezeichnung	Modul MP-B: Mathematik für Physikstudierende B (englische Übersetzung: Mathematics for Physicists B)	ECTS 10
2	Lehrveranstaltungen	Vorlesung Mathematik für Physikstudierende B (4 SWS) Übungen zu Mathematik für Physikstudierende B (2 SWS)	
3	Lehrende	Dr. Daniel Tenbrinck daniel.tenbrinck@fau.de	
4	Modulverantwortung	Prof. Dr. Andreas Knauf knauf@math.fau.de	
5	Inhalt	<ul style="list-style-type: none"> • Integrationstechniken: Partielle Integration, rationale Funktionen einer Unbestimmten etc. • Matrizen und Endomorphismen endlich-dim. Vektorräume: Jordansche Normalform, adjungierte und normale, selbstadjungierte, orthogonale und unitäre Matrizen, Projektionen • Quadratische Formen: Kegelschnitte, Normalform für gekoppelte harmonische Oszillatoren • Lineare Differentialgleichungen mit konstanten Koeffizienten: Lösung mittels Exponentiation von Matrizen bzw. mit charakteristischem Polynom • Topologie und Stetigkeit: Wiederholung: Metrik und Norm, Grenzwerte und Stetigkeit; Topologie, Kompaktheit • Nullstellen von Funktionen: Newtonverfahren, Banachscher Fixpunktsatz • Gewöhnliche Differentialgleichungen: Lokale und globale Existenz und Eindeutigkeit der Lösung, Phasenportrait • Differentialrechnung mehrerer Variablen: Vektorfelder, totale Ableitung, partielle Ableitungen, Extrema, Sattelpunkte, Höhenlinien, Gradient • Differentiationsregeln: Anwendungen der Kettenregel, Höhere Ableitungen, Funktionaldeterminante • Der Satz von Taylor im \mathbb{R}^n: Multiindexschreibweise, Hessematrix, Extremalstellen • Implizite Funktionen: Vereinfachtes Newtonverfahren, Konstruktion der impliziten Funktionen • Extrema mit Nebenbedingungen: Parametrisierung der Nebenbedingungen, Lagrange-Multiplikatoren <p>Die Präsentation des Stoffes erfolgt in Vorlesungsform. Die weitere Aneignung der wesentlichen Begriffe und Techniken erfolgt durch wöchentliche Hausaufgaben.</p>	
6	Lernziele und Kompetenzen	<p>Die Studierenden</p> <ul style="list-style-type: none"> • können große Klassen von Funktionen einer Variablen integrieren; • benutzen die Ableitung einer Funktion mehrerer Variablen zur Lösung von Extremalproblemen; • kennen in der Physik wichtige Typen linearer Endomorphismen und können damit lineare gewöhnliche Differentialgleichungen lösen; • wenden die entsprechenden Verfahren selbstständig zur Lösung physikalischer Probleme an. 	

7	Voraussetzungen für die Teilnahme	empfohlen: Mathematik für Physikstudierende A
8	Einpassung in Musterstudienplan	2. Semester
9	Verwendbarkeit des Moduls	Pflichtmodul in <ul style="list-style-type: none"> • B. Sc. Physik
10	Studien- und Prüfungsleistung	Klausur (90 Min.)
11	Berechnung Modulnote	Klausur (100 %)
12	Turnus des Angebots	jährlich im Sommersemester
13	Arbeitsaufwand	Workload 225 h davon: <ul style="list-style-type: none"> • Vorlesung: 4 SWS x 15 = 60 h • Übung: 2 SWS x 15 = 30 h • Selbststudium: 135 h
14	Dauer des Moduls	ein Semester
15	Unterrichts- und Prüfungssprache	deutsch
16	Literaturhinweise	<ul style="list-style-type: none"> • T. Arens, F. Hettlich, C. Karpfinger, U. Kockelkorn, K. Lichtenegger, H. Stachel: Mathematik • Skript (A. Knauf): Mathematik für Physikstudierende 2

Modulbezeichnung	dModul MFDL: Mathematische Forschung zu Deep Learning (englische Übersetzung: AG Mathematics of Deep Learning)	ECTS 5
Lehrveranstaltungen	AG Mathematics of Deep Learning	
Lehrende	1. Dr. Daniel Tenbrinck daniel.tenbrinck@fau.de 2. Dr. Leon Bungert leon.bungert@fau.de	
Modulverantwortung	Dr. Daniel Tenbrinck daniel.tenbrinck@fau.de	
Inhalt	Führende Wissenschaftler*innen der FAU und von anderen nationalen und internationalen Universitäten halten Vorträge über den aktuellen Stand der Forschung in folgenden Themengebieten: <ul style="list-style-type: none"> • Modellierung von Regressions- und Klassifikationsproblemen aus der Data Science mittels neuronaler Netze • Großskalierte stochastische Optimierungsmethoden für das Training von tiefen neuronalen Netzen • Regularisierungsstrategien für verbesserte Stabilität von neuronalen Netzen • Neuronale Netzwerk Architekturen für verschiedene Anwendungen • Mathematische Analyse von Stabilität, Aussagekraft und Generalisierungsfähigkeit von tiefen neuronalen Netzen • Gewöhnliche Differentialgleichungen durch neuronale Netze und Verbindungen zu Mathematischer Kontrolltheorie 	
Lernziele und Kompetenzen	Die Studierenden <ul style="list-style-type: none"> • Formulieren offene Forschungsfragestellungen aus dem Bereich des maschinellen Lernens und insbesondere dem Deep Learning • Erklären die Vor- und Nachteile von Deep Learning in verschiedenen Anwendungen • Formulieren das Training von neuronalen Netzen als mathematisches Optimierungsproblem • Erklären verschiedene Strategien zur Stabilisierung des Trainings von neuronalen Netzen • Erklären die Wichtigkeit von stochastischen Optimierungsmethoden für das Training von neuronalen Netzen • Diskutieren die Verbindungen zwischen Deep Learning, Optimaler Kontrolltheorie und Regularisierungstheorie 	
Voraussetzungen für die Teilnahme	Fundiertes Wissen in Analysis, Linearer Algebra und Optimierung	
Einpassung in Musterstudienplan	6. Semester	
Verwendbarkeit des Moduls	Wahlpflichtmodul: <ul style="list-style-type: none"> • B.Sc. Data Science (Vertiefungsbereich Maschinelles Lernen / AI) 	
Studien- und Prüfungsleistung	Klausur (60 min.) oder mündliche Prüfung	
Berechnung Modulnote	Klausur oder mündliche Prüfung (100%)	
Turnus des Angebots	2 x jährlich im SoSe und WiSe	
Arbeitsaufwand	Workload: 150h davon: <ul style="list-style-type: none"> • AG: 2 SWS x 15 = 30h • Eigenstudium: 120h 	

Dauer des Moduls	1 Semester
Unterrichts- und Prüfungssprache	englisch
Literaturhinweise	Literaturhinweise werden durch die Vortragenden bekannt gegeben