

Machine Learning Basics

Seminarunterlage

Version: 1.01



Dieses Dokument wird durch die ORDIX AG veröffentlicht.

Copyright ORDIX AG. Alle Rechte vorbehalten.

Alle Produkt- und Dienstleistungs-Bezeichnungen sind Warenzeichen oder eingetragene Warenzeichen der jeweiligen Firmen und beziehen sich auf Eintragungen in den USA oder USA-Warenzeichen.

Weitere Logos und Produkt- oder Handelsnamen sind eingetragene Warenzeichen oder Warenzeichen der jeweiligen Unternehmen.

Kein Teil dieser Dokumentation darf ohne vorherige schriftliche Genehmigung der ORDIX AG weitergegeben oder benutzt werden.

Adressen der ORDIX AG

Die ORDIX AG besitzt folgende Geschäftsstellen

ORDIX AG
Karl-Schurz-Straße 19a
D-33100 Paderborn
Tel.: (+49) 0 52 51 / 10 63 - 0
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
An der alten Ziegelei 5
D-48157 Münster
Tel.: (+49) 02 51 / 9 24 35 – 00
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
Welser Straße 9
D-86368 Gersthofen
Tel.: (+49) 08 21 / 507 492 – 0
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
Kreuzberger Ring 13
D-65205 Wiesbaden
Tel.: (+49) 06 11 / 7 78 40 – 00
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
Wikingerstraße 18-20
D-51107 Köln
Tel.: (+49) 02 21 / 8 70 61 – 0
Fax.: (+49) 01 80 / 1 67 34 90

ORDIX AG
Gewerbegebiet Süd-West Park
Südwestpark 67/2
D-890449 Nürnberg
Tel.: (+49) 0 52 51 / 10 63 - 0
Fax.: (+49) 01 80 / 1 67 34 90

Internet: <http://www.ordix.de>

Email: seminare@ordix.de

Inhaltsverzeichnis

1	Einführung	5
1.1	Einführung.....	6
1.2	Begriffsabgrenzung.....	7
2	Lineare Regression	10
2.1	Gliederung.....	11
2.2	Lineare Regression.....	13
2.3	Multivariate lineare Regression.....	17
2.4	Lineare Regression mit Basiserweiterung.....	21
2.5	Lineare Regression: Addendum.....	23
2.6	Statistische Grundlagen.....	24
2.7	Lagemaße.....	25
2.8	Streuemaße.....	27
2.9	Zusammenhangsmaße.....	29
2.10	Skalenniveaus.....	31
2.11	Kenngrößen der Regression.....	35
2.12	Kenngrößen der Regression: Addendum.....	40
2.13	Vor- und Nachteile von linearen Regressionsmodellen.....	41
3	k-Nächste-Nachbarn	42
3.1	Gliederung.....	43
3.2	k-Nächste-Nachbarn.....	45
3.3	Holdout-Validierung & Hyperparameter-Tuning.....	50
3.4	Holdout-Validierung.....	51
3.5	Hyperparameter-Tuning.....	52
3.6	AHoldout-Validierung & Hyperparameter-Tuning Addendum:.....	56
3.7	Kennzahlen der Klassifikation.....	58
3.8	Kennzahlen der Klassifikation: Addendum.....	63
3.9	Vor- und Nachteile von k-Nächsten Nachbarn.....	64
4	Decision Trees	65
4.1	Gliederung.....	66
4.2	Decision Trees.....	67
4.3	Decision Trees: Addendum.....	74
4.4	Explorative Datenanalyse.....	75
4.5	Explorative Datenanalyse: Addendum.....	83
4.6	Data Engineering: Variablenselektion & Data Cleansing.....	84
4.7	Data Engineering: Data Cleansing.....	86
4.8	Data Engineering: Variablenselektion.....	88
4.9	Data Engineering: Data Transformation.....	91
4.10	Overfitting & Underfitting.....	93
4.11	Decision Tree Pruning.....	97
4.12	Vor- und Nachteile von Decision Trees.....	100
5	Ensemble-Modelle	101
5.1	Gliederung.....	102
5.2	Ensemble-Modelle.....	103
5.3	Random Forests.....	107
5.4	AdaBoost.....	110
5.5	Vor- und Nachteile von Ensemble-Modellen.....	114
5.6	Data Science Pipeline.....	115
5.7	Komplexaufgabe.....	120
6	Neuronale Netze	122
6.1	Gliederung.....	123
6.2	Neuronale Netze.....	124
6.3	Backpropagation.....	129
6.4	Vertiefung neuronale Netze.....	132

6.5	Vor- und Nachteile von neuronalen Netzen	137
6.6	Data Engineering: Transformation & Feature Engineering.....	138
6.7	Data Engineering: Data Transformation	140
6.8	Data Engineering: Feature Engineering.....	145
6.9	Kreuzvalidierung	148
7	Unsupervised Learning	153
7.1	Gliederung.....	154
7.2	Machine Learning: Ein Überblick	155
7.3	Clustering	159
7.4	K-means.....	161
8	Schlussteil.....	166
8.1	Gliederung.....	167
8.2	Modellüberblick	168
8.3	Technologie-Stack	170
8.4	Best Practices	172
8.5	Feedbackrunde	174