

Professur für Hydrologie

Fakultät für Umwelt und natürliche Ressourcen

Albert-Ludwigs-Universität Freiburg i. Br.

Simon Trust

**Analyse des Dürrierisikos für den Forstsektor
anhand von Dürreindices und Wirkungsberichten
in Deutschland**

Referentin: Prof. Dr. Kerstin Stahl

Korreferentin: Julia Schwarz

Masterarbeit unter der Leitung von Prof. Dr. Kerstin Stahl

Freiburg im Breisgau, Dezember 2019

Inhaltsverzeichnis

Inhaltsverzeichnis	I
Verzeichnis der Abbildungen im Text	IV
Verzeichnis der Tabellen im Text.....	VII
Verzeichnis der Abbildungen im Anhang	VIII
Verzeichnis der Tabellen im Anhang.....	X
Abkürzungsverzeichnis	XI
Vorwort	XIII
Zusammenfassung	XV
Extended English summary	XVII
1 Einleitung	1
1.1 Naturphänomen Dürre – Charakteristik, Definitionen, Auswirkungen	1
1.2 Klimatologie Deutschlands und der Einfluss des Klimawandels	5
1.3 Dürreauswirkungen im Forst.....	7
1.4 Stand des Wissens	10
1.4.1 Vulnerabilitäts- und Risikoanalyse	10
1.4.2 Dürreindices	11
1.4.3 Dürerrerisikoanalysen anhand von Wirkungsberichten	12
1.4.4 Kronenentlaubung als Zeiger für die Waldgesundheit.....	14
2 Problemstellung und Zielsetzung.....	17
3 Methoden.....	19
3.1 Untersuchungsgebiet	19
3.1.1 Forstliche Flächen in Deutschland.....	19
3.1.2 NUTS-Regionen	20
3.2 Datengrundlage und Datenaufbereitung	22
3.2.1 Dürre Indices: SPI, SPEI und SMI	22
3.2.2 Auswirkungsdaten von Dürre.....	25
3.3 Statistische Analysen	31

3.3.1	Vorausgehende Untersuchungen von Indices und Auswirkungsdaten (EDII)	31
3.3.2	Logistische Regression.....	32
3.3.3	ROC-Analyse (Receiver Operating Characteristics)	33
3.3.4	Dürrierisikokarten für Deutschland	34
3.3.5	ICP Forest Daten – Voruntersuchungen und Trendanalysen	35
3.3.6	Linear Mixed Effect Models – ICP Forest Daten	35
4	Ergebnisse	39
4.1	Dürreindices	39
4.2	EDII Daten	41
4.2.1	Vorausgehende Analysen des Zusammenhangs zwischen Indices – Auswirkungen (EDII)	42
4.2.2	Logistische Regression.....	43
4.2.3	ROC Analyse.....	47
4.2.4	Logistische Regression mit einem Jahr Zeitversatz	48
4.2.5	Dürrierisikokarten für Deutschland	49
4.3	ICP Forest Daten	52
4.3.1	Trendanalysen.....	52
4.3.2	Linear Mixed Effect Models	57
5	Diskussion	69
5.1	Dürreindices	69
5.2	EDII – Datenbank.....	70
5.3	Logistische Regression	71
5.3.1	ROC-Analyse	73
5.3.2	Logistische Regression mit einem Jahr Zeitversatz	73
5.3.3	Dürrierisikokarten.....	74
5.4	ICP Forest Daten	75
5.4.1	Datenunsicherheit und Trendanalyse	75
5.4.2	Linear Mixed Effect Models	77
6	Schlussfolgerungen und Ausblick	83
	Literaturverzeichnis	87

Anhang	97
Abbildungen	97
Tabellen.....	120
Ehrenwörtliche Erklärung	129

Verzeichnis der Abbildungen im Text

Abbildung 1: Konzept der Dürreausbreitung nach van Loon et al. (2016). Durch natürliche Klimavariabilität induzierte Dürren (meteorologisch, landwirtschaftlich und hydrologisch) können zusätzlich durch menschlichen Einfluss verstärkt oder abgeschwächt werden und haben sowohl in Umwelt- als auch in sozioökonomischen Bereichen Auswirkungen.	3
Abbildung 2: CORINE Landnutzungsklassen 3.1.1 (Laubwälder), 3.1.2 (Nadelwälder), 3.1.3 (Mischwälder) und 3.2.4 (Wald/Strauch Übergangsvegetation) in Deutschland für das Bezugsjahr 2018 (Auflösung 25 ha)	20
Abbildung 3: NUTS-1 und NUTS-2-Ebenen in Deutschland. (Maximilian Dörrbecker (Chumwa) - Eigenes Werk, CC BY-SA 2.5, https://commons.wikimedia.org/w/index.php?curid=6779016)....	21
Abbildung 4: Anzahl der EDII Einträge in der Kategorie Forst je Bundesland ab 1975	27
Abbildung 5: Prozentuale Anzahl der Unterkategorien der EDII Einträge im Forstsektor in Deutschland ab 1975. 2.1: Vermindertes Baumwachstum/Vitalität; 2.2: Abnahme jährlicher Nichtholzprodukte (Kork etc.); 2.3: Erhöhtes Auftreten von Wasserstressindikatoren und Schadenssymptomen (Kronenentlaubung etc.); 2.4: Zunahme von Baumkrankheiten oder Schädlingen; 2.5: Zunehmendes Baumsterben; 2.6: Zunehmendes Absterben von Baumsetzlingen (in bewirtschafteten Gebieten); 2.8: andere Auswirkungen; 2.9: Zunahme von wirtschaftlichen Verlusten/Kosten	28
Abbildung 6: ICP Forest Level-I Stände in Deutschland (613 insgesamt)	30
Abbildung 7: Beispiel für eine ROC-Kurve. Bei einem Schwellenwert von 18,5 wird der maximale Abstand zur Diagonalen erreicht. Für diesen Schwellenwert würden eine Sensitivität von 0,94 erreicht werden, d.h., dass 94% aller Auswirkungen korrekt vorhergesagt werden. Zugleich werden 24% der Ereignisse zu Unrecht als solche klassifiziert (1 – Spezifität). Entnommen aus Moosbrugger und Kelava .(2012)	34
Abbildung 8: Zeitreihen der Dürreindices je NUTS-2-Region (schwarze Linie) von 1975-2018 und lineare Trendgerade (rot).....	40
Abbildung 9: Boxplots des Wertebereichs der Dürreindices.	41
Abbildung 10: Zeitreihe berichteter Dürreauswirkungen (skalierte EDII-Daten) für jede NUTS-2-Region seit 1975. „TRUE“, wenn mindestens von einer Dürreauswirkung im Forstsektor in diesem Jahr für diese Region berichtet wurde.	42
Abbildung 11: Zusammenhang zwischen Werten der Dürreindices und prozentualem Anteil der Jahre mit berichteten Auswirkungen (ja/nein). Grafik nach Gauster und Stagge (2019).....	43
Abbildung 12: Dürreindex mit dem besten Modellfit (McFaddens pseudo-R ²) je NUTS-2 Region. Für NUTS-2-Regionen in hellgrau konnte kein signifikanter Index ermittelt werden.	45
Abbildung 13: NUTS-2-Regionen, in denen SPEI 6 und SPI 24 signifikanter Prädiktor (logistische Regression, $p \leq 0.05$) für das Auftreten von Dürreauswirkungen (binär: Ja/Nein) sind (GRÜN) bzw.	

nicht-signifikant sind (ROT). Der SPEI 6 ist mit 25 NUTS-2-Regionen am häufigsten, der SPI 24 mit neun Regionen am seltensten signifikant.	46
Abbildung 14: Zusammenhang zwischen Index und Wahrscheinlichkeit einer Auswirkung (likelihood). Links: SPEI 3 in NUTS-2 DE11; rechts: SPEI 6 in NUTS-2 DEA2. Die Balkendiagramme bilden den jeweiligen Wertebereich des Index für berichtete Auswirkungen (impact) und keine berichtete Auswirkung (no impact) ab. Abbildungen nach Gauster und Stagge (2019).	47
Abbildung 15: ROC-Kurven für die NUTS-2-Regionen DE12 und DEA2 Auf der y-Achse der Anteil korrekt vorhergesagter Auswirkungen (Sensitivität bzw. true positive rate TPR), auf der x-Achse der Anteil falsch vorhergesagter Auswirkungen (1 – Sensitivität oder false positive rate FPR).....	48
Abbildung 16: Rot: NUTS-2-Regionen, in denen keiner der zehn untersuchten Dürreindices ein signifikanter Prädiktor ($p < 0,05$) für Dürreauswirkungen des Folgejahrs ist. Grün: NUTS-2-Regionen, in denen mindestens ein Dürreindex signifikant ist.....	49
Abbildung 17: Modellerte Auftretswahrscheinlichkeiten (LIO) von Dürreauswirkungen im Forst in Deutschland für den SPEI 6 (-1; -1,5).....	50
Abbildung 18: Modellerte Auftretswahrscheinlichkeiten (LIO) von Dürreauswirkungen im Forst in Deutschland für den SPEI 6 (-2; -2,5).....	51
Abbildung 19: Zeitreihen der Kronenentlaubung für die vier Hauptbaumarten (Fagus, Picea, Pinus, Quercus sp.) aller beobachteten Bäume in Deutschland.	52
Abbildung 20: Spaghetti Diagramme der Kronenentlaubung der vier Hauptbaumgattungen (Fagus, Picea, Pinus, Quercus sp.) für jede NUTS-2-Region plus gewichtetes, gleitendes Mittel (LOESS)	53
Abbildung 21: Autokorrelation der Kronenentlaubung der vier Hauptbaumarten in Deutschland.	54
Abbildung 22: Mann-Kendall Trendtest für die korrigierten Zeitreihen von Fagus und Picea pro NUTS-2 Region. Der Farbverlauf gibt die Stärke des Trends an. Positive Werte für Kendall's tau (rot) stehen für eine signifikante Zunahme der Kronenentlaubung in der jeweiligen NUTS-2 Region, negative Werte (grün) für eine signifikante Abnahme. Für grau gekennzeichneten NUTS-2-Regionen konnte kein signifikanter Trend festgestellt werden.....	55
Abbildung 23: Mann-Kendall Trendtest für die korrigierten Zeitreihen von Pinus und Quercus pro NUTS-2 Region. Der Farbverlauf gibt die Stärke des Trends an. Positive Werte für Kendall's tau (rot) stehen für eine signifikante Zunahme der Kronenentlaubung in der jeweiligen NUTS-2 Region, negative Werte (grün) für eine signifikante Abnahme. Für grau gekennzeichneten NUTS-2-Regionen konnte kein signifikanter Trend festgestellt werden.....	56
Abbildung 24: Histogramme der Kronenentlaubung der vier Hauptbaumarten in Deutschland	57
Abbildung 25: Histogramme der Wurzeltransformierten Kronenentlaubungsdaten (+5% je Datenpunkt)	58
Abbildung 26: Q-Q-Diagramme der Wurzeltransformierten Kronenentlaubungsdaten	59
Abbildung 27: Korrelationsmatrix mit Spearmans rho der möglichen Prädiktoren (fixed effects).....	60

Abbildung 28: Darstellung der Pearson Residuen gegen die angepassten Modellwerte aller vier Baumarten	62
Abbildung 29: Q-Q-Diagramme der Pearson Residuen der finalen Modelle aller vier Baumarten	63
Abbildung 30: Pearson Residuen – Prädiktoren. Baumart: Fagus.....	64
Abbildung 31: Zusammenhang zwischen Kronenentlaubung und durchschnittlichem Standalter und gleitendes Mittel (LOESS).	66

Verzeichnis der Tabellen im Text

Tabelle 1: Prozentualer Anteil der Waldfläche je Bundesland (2012) (BMLE, 2017)	19
Tabelle 2: Dürre Klassifikation für SPI und SPEI (McKee et al., 1993; Spinoni et al., 2016).....	23
Tabelle 3: Auswahl der random effect Struktur bei gleichbleibender fixed effect Struktur für die LMMs. Die fixed effects waren Dürreindex, Standalter, Standhöhe (m.a.s.l.), nFK und Beobachtungsjahr.	37
Tabelle 4: Mittelwerte von McFaddens pseudo- R^2 für alle Indices, die in einer NUTS-2-Region ein signifikanter Prädiktor für Dürreauswirkungen sind. Des Weiteren Anzahl der NUTS-2-Regionen, in denen der Index signifikanter Prädiktor ist.....	45
Tabelle 5: Mittelwerte von McFaddens pseudo- R^2 für alle Indices, die in einer NUTS-2-Region ein signifikanter Prädiktor für Dürreauswirkungen im Folgejahr waren. Des Weiteren Anzahl der NUTS-2-Regionen, in denen die Indices signifikanter Prädiktor war	48
Tabelle 6: Ergebnisse des nicht-parametrischen Mann-Kendall Trendtests der korrigierten (Autokorrelation herausgerechnet) Kronenentlaubungszeitreihen (1990 – 2018).....	53
Tabelle 7: NUTS-2-Regionen, in denen die Kronenentlaubung an weniger als zehn Bäumen erhoben wurde.....	56
Tabelle 8: Schätzer der Parameter inklusive Standardfehler (S.E.) und p-Wert für die fixed effects sowie Standardabweichung der random effects der linear mixed models (angepasst mit REML). Für die random effects wurde jeweils der Anteil erklärter Varianz bei gegebener fixed effect Struktur berechnet (Angaben in Prozent). Die fixed effects wurden standardisiert, wodurch ihr Einfluss direkt miteinander verglichen werden kann.	65
Tabelle 9: NUTS-2-Regionen ohne signifikanten Index, Anteil bewaldeter Fläche der zugehörigen Bundesländer und Anzahl der EDII Einträgen (n) seit 1975	71

Verzeichnis der Abbildungen im Anhang

Abbildung Anhang 1: Korrelationsmatrix aller Dürreindices sowie des Beobachtungsjahres (Pearson's r)	97
Abbildung Anhang 2: NUTS-2-Regionen, in denen SMI 180, SMI 25, SPI 12 und SPI 6 signifikanter Prädiktor (logistische Regression, $p \leq 0.05$) für das Auftreten von Dürreauswirkungen waren (Grün).....	98
Abbildung Anhang 3: NUTS-2-Regionen, in denen SPEI 3, SPEI 12, SPEI 24 und SPI 3 signifikanter Prädiktor (logistische Regression, $p \leq 0.05$) für das Auftreten von Dürreauswirkungen waren (Grün).....	99
Abbildung Anhang 4: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DE11, DE12, DE13, DE14.....	100
Abbildung Anhang 5: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DE21, DE22, DE23, DE24.....	101
Abbildung Anhang 6: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DE25, DE26, DE27, DE40.....	102
Abbildung Anhang 7: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DE71, DE72, DE72, DEA1	103
Abbildung Anhang 8: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DEA2, DEA3, DEA5, DEB1	104
Abbildung Anhang 9: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DEB2, DEB3, DEC0, DED2.....	105
Abbildung Anhang 10: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DED4, DED5.....	106
Abbildung Anhang 11: ROC-Kurven für DE11	106
Abbildung Anhang 12: ROC-Kurven für DE12, DE13, DE14 und DE21	107
Abbildung Anhang 13: ROC-Kurven für DE22 und DE23	108
Abbildung Anhang 14: ROC-Kurven für DE24, DE25, DE26 und DE27	109
Abbildung Anhang 15: ROC-Kurven für DE40, DE71, DE72, DE73 und DEA1	110
Abbildung Anhang 16: ROC-Kurven DEA2, DEA3, DEA5, DEB1, DEB2 und DEB3	111
Abbildung Anhang 17: ROC-Kurven DEC0, DED2, DED4 und DED5	112
Abbildung Anhang 18: LMMs: Pearson Residuen gegen fixed effects für Picea (ICP Forest Daten)	113
Abbildung Anhang 19: LMMs: Pearson Residuen gegen fixed effects für Pinus (ICP Forest Daten)	114
Abbildung Anhang 20: LMMs Pearson Residuen gegen fixed effects für Quercus sp. (ICP Forest Daten)	114
Abbildung Anhang 21: Zusammenhang zwischen fixed effects und Kronenentlaubung für Fagus..	115

Abbildung Anhang 22: Zusammenhang zwischen fixed effects und Kronenentlaubung für Picea...	116
Abbildung Anhang 23: Zusammenhang zwischen fixed effects und Kronenentlaubung für Pinus ..	117
Abbildung Anhang 24: Zusammenhang zwischen fixed effects und Kronenentlaubung für Quercus sp.	118
Abbildung Anhang 25: Jährliches Schadholz durch Insekten je Bundesland von 2005 – 2018 (Daten des Statistischen Bundesamts).....	119

Verzeichnis der Tabellen im Anhang

Tabelle Anhang 1: Anzahl der Jahre mit mindestens einem EDII Eintrag pro Jahr und NUTS-2 Region	120
Tabelle Anhang 2: Zusammenfassende Statistiken für die Verteilung von Indices vs. Auswirkungen	120
Tabelle Anhang 3: Durchschnittliche Anzahl der Bäume je NUTS-2 Region, an denen der Parameter Kronenentlaubung erhoben wurde sowie Ergebnisse des Mann-Kendall Trendtests: Zunahme (+), Abnahme (-) oder kein Trend (0).....	121
Tabelle Anhang 4: Jährlicher durch Insekten verursachter Holzeinschlag zwischen 2005 – 2018 je Bundesland.....	122

Abkürzungsverzeichnis

Abkürzung	Bedeutung
AIC	Akaike Information Criterion
AC	Autokorrelation
AUC	Area Under Curve
BB	Brandenburg
BE	Berlin
BMLE	Bundesministerium für Landwirtschaft und Ernährung
BW	Baden-Württemberg
BY	Bayern
C3S	Copernicus Climate Change Service
CDC	Climate Data Center (DWD)
CLC	CORINE Land Cover Daten
Destatis	Statistisches Bundesamt
DWD	Deutscher Wetterdienst
EDC	European Drought Centre
EDII	European Drought Impact report Inventory
EDO	European Drought Observatory
EK	Europäische Kommission
GAMM	Generalized additive mixed model
GLM	Generalized linear model
GMD	German Drought Monitor (Deutscher Dürremonitor)
HE	Hessen
ICP F	International Co-operative Programme on Assessment und Monitoring of Air Pollution Effects on Forests
IPCC	Intergovernmental Panel on Climate Change
LIO	Likelihood of impact occurrence
LMM	Linear mixed effect model
mHM	Mesoskalisches hydrologisches Modell
ML	Maximum Likelihood
MV	Mecklenburg-Vorpommern
nFK	Nutzbare Feldkapazität
NI	Niedersachsen
NUTS	Nomenclature des unités territoriales statistiques
NW	Nordrhein-Westfalen

OLR	Ordinary least squares
REML	Restricted Maximum Likelihood
ROC	Receiver Operating Characteristic
RP	Rheinland-Pfalz
S.E.	Standard Fehler
SH	Schleswig-Holstein
SL	Saarland
SMI	Soil Moisture Index
SN	Sachsen
SPEI	Standardized Precipitation-Evaporation Index
SPI	Standardized Precipitation Index
ST	Sachsen-Anhalt
TH	Thüringen
UFZ	Helmholtz-Zentrum für Umweltforschung
WMO	World Meteorological Organization
μ	Mittelwert
σ	Standardabweichung

Vorwort

Vorab möchte ich mich bei einigen Menschen bedanken, welche mich bei der Erstellung dieser Masterarbeit auf unterschiedliche Weise unterstützt haben.

Ich danke Prof. Dr. Kerstin Stahl und Julia Schwarz für die Betreuung dieser Arbeit und die Antwort auf zahlreiche Nachfragen. Ich danke Jost Hellwig für die Bereitstellung der meteorologischen Dürreindices, Irene Kohn für die Einführung in die EDII Datenbank und Veit Blauhut für die Anregungen bei der Auswertung meiner Ergebnisse. Ein besonderer Dank geht an Jim Stagge für die Bereitstellung seines R-Codes zum Thema logistische Regression und die detaillierten Antworten auf meine Nachfragen. Ich möchte dem Thuenen Institut für die Bereitstellung der ICP Forest Daten danken.

Ein großes Dankeschön an Anja, Ferdi, Raphi und Lena für das Korrekturlesen und die vielen klugen Anmerkungen.

Zu guter Letzt danke ich meinen Eltern für ihre vielfältige Unterstützung während meiner Studienzeit sowie meinen vielen tollen Freunden und meiner Liebe dafür, dass es sie gibt und sie die Zeit in Freiburg so wunderschön machen.

Zusammenfassung

Eine Vielzahl von Regionen in Deutschland wurde in den letzten Jahrzehnten immer häufiger von Dürre betroffen. Zu den betroffenen Sektoren zählt auch die Forstwirtschaft. Klimatischer Stress beeinflusst negativ die Baumvitalität und Waldgesundheit und kann zu einem Versagen der hydraulischen Leitfähigkeit, Kohlenstoffmangel und dem Befall der Bäume durch biotische Schadfaktoren führen. In dieser Masterarbeit wurden verschiedene Informationen zu Auswirkungen von Dürre auf die Forstwirtschaft in Deutschland gesammelt und im Rahmen einer statistischen Risikoanalyse mit verschiedenen Dürreindices in Verbindung gesetzt. Neben dem meteorologischen *Standardized Precipitation Index* (SPI) und *Standardized Precipitation Evaporation Index* (SPEI) wurde der Bodenfeuchteindex SMI verwendet. Viele Monitoring- und Frühwarnsysteme prognostizieren die meteorologische Dürregefahr, liefern jedoch keine Informationen darüber, wann und wo ein Niederschlagsdefizit zu negativen Folgen führen kann. Aufgrund dessen wurde im ersten Teil der Arbeit das Dürrierisiko auf NUTS-2-Ebene in Deutschland durch den funktionellen Zusammenhang zwischen textbasierten Auswirkungsdaten der *European Drought Impact report Inventory* (EDII) Datenbank und den Dürreindices seit 1975 bewertet. Mittels logistischer Regression wurde die Auftrittswahrscheinlichkeit von Dürreauswirkungen auf jährlicher Basis modelliert und das Bestimmtheitsmaß der Dürreindices miteinander verglichen. Dabei erwies sich der SPEI-6 im Mittel als bester Modellindex. Die erstellten Dürrierisikokarten weisen die niederen, nördlichen Wuchsregionen von Baden-Württemberg und Bayern als besonders gefährdet aus. Allerdings ist die Anzahl der berichteten Auswirkungen in vielen Regionen limitierend für die Modelle, weshalb für einige Regionen Nord- und Zentraldeutschlands keine signifikanter Zusammenhang zwischen Indices und Auswirkungen bestimmt werden konnten. Die Charakteristik der zeitversetzten Reaktion forstlicher Systeme auf Dürreereignisse konnte sich über die gewählte Methodik nicht erfassen werden.

Im zweiten Teil der Arbeit wurden Kronenentlaubungsdaten der ICP Forest für die vier Hauptbaumarten Buche (*Fagus sylvatica*), Fichte (*Picea albies*), Kiefer (*Pinus sylverstris*) und Eichen (*Quercus sp.*) auf räumliche und zeitliche Trends seit 1990 untersucht. Für *Fagus* und *Picea* ist ein signifikanter Anstieg der Kronenentlaubung zu beobachten, was auf eine Zunahme der Lufttemperatur und akkumulierende Effekte aufeinanderfolgender Dürrejahre zurückzuführen ist. Des Weiteren wurde der Zusammenhang zwischen Kronenentlaubung und Dürreindices mittels *linear mixed effect models* (LMMs) modelliert. Die Bodenfeuchteindices SMI 180 und SMI 25 eignen sich am besten für die Modellierung der Kronenentlaubung der vier Baumarten. Einen deutlich größeren Einfluss haben jedoch das durchschnittliche Standalter sowie die räumliche Varianz zwischen den Standorten. Daraus lässt sich schließen, dass das Standalter sowie der artenspezifische Zusammenhang zwischen Entlaubung und Alter den generellen Grad der Entlaubung bestimmen, während Fluktuationen durch klimatische Bedingungen wie Dürre bedingt sind.

Stichworte: Dürrierisikoanalyse, Forstsektor, text-basierte Auswirkungsberichte, *European Drought Impact report Inventory* (EDII), Logistische Regression, Standardisierter Niederschlagsindex (SPI), Standardisierte Niederschlags-Verdunstungsindex (SPEI), *Soil Moisture Index* (SMI), ICP Forest, Kronenentlaubung, *linear mixed effect models* (LMMs), Standalter, *Fagus sylvatica*, *Picea abies*, *Pinus sylvestris*, *Quercus sp.*

Extended English summary

Many regions in Germany have been increasingly affected by drought in recent decades with forestry being one of the sectors affected. Climatic stress has a negative impact on tree vitality and forest health and can lead to failure of hydraulic conductivity, carbon starvation and infestation of trees by biotic agents. In this master thesis, various information on the effects of drought on forestry in Germany was collected and linked to various drought indices as part of a statistical risk analysis. In addition to the meteorological Standardized Precipitation Index (SPI) and Standardized Precipitation Evaporation Index (SPEI), the soil moisture index SMI was used. Many monitoring and early warning systems forecast the meteorological drought risk, but do not provide information on when and where a precipitation deficit can lead to negative consequences. Therefore, in the first part of the paper, the drought risk at NUTS-2 level in Germany was assessed by the functional relationship between text-based impact data from the European Drought Impact report Inventory (EDII) database and the drought indices since 1975. By means of logistic regression, the likelihood of drought impact occurrence was modelled on an annual basis and the coefficient of determination of the drought indices was compared. On average, the SPEI-6 proved to be the best model index. The produced drought risk maps show the lower, northern growing regions of Baden-Württemberg and Bavaria as particularly endangered. However, the number of reported impacts in many regions limits the models, which is why no significant correlation between indices and impacts could be determined for some regions of northern and central Germany. The characteristics of the delayed response of forest systems to drought events cannot be determined by the chosen methodology.

In the second part of the study, crown defoliation data of the ICP Forest for the four main tree species beech (*Fagus sylvatica*), spruce (*Picea albies*), pine (*Pinus sylverstris*) and oak (*Quercus sp.*) were investigated for spatial and temporal trends since 1990. For *Fagus* and *Picea* a significant increase in crown defoliation can be observed, which is due to an increase in temperatur and accumulating effects of successive years of drought. Furthermore, the relationship between crown defoliation and drought indices was modelled using linear mixed effect models (LMMs). The soil moisture indices SMI 180 and SMI 25 are best suited for modelling crown defoliation of the four tree species. However, the average age of the trees and the spatial variance between the locations have a much greater influence. From this it can be concluded that stand age and the species-specific relationship between defoliation und age determine the general degree of defoliation, while fluctuations are caused by climatic conditions such as drought.

Keywords: statistical drought risk analysis, forestry, text-based impact reports, European Drought Impact report Inventory (EDII), logistic regression, Standardized Precipitation Index (SPI), Standardized Precipitation Evaporation Index (SPEI), Soil Moisture Index (SMI), ICP Forest, crown defoliation, linear mixed effect models (LMMs), stand age, *Fagus sylvatica*, *Picea albies*, *Pinus sylverstris*, *Quercus sp.*

1 Einleitung

1.1 Naturphänomen Dürre – Charakteristik, Definitionen, Auswirkungen

Dürren sind komplexe Naturereignisse, welche als natürlicher Bestandteil des Klimas in unterschiedlichen Wiederkehrperioden in beinahe allen Regionen der Erde zu jeder Jahreszeit auftreten können und alle Wirtschaftsformen, Industrie- wie Entwicklungsländern zugleich, betreffen (Wilhite, 2000; Wilhite und Vanyarkho, 2000; Mishra und Singh, 2010; Bachmair et al., 2016a). Hinsichtlich der Anzahl betroffener Menschen stehen Dürren vor allen anderen Naturkatastrophen weltweit auf Rang eins (Obasi, 1994; Wilhite, 2000). Sie zeichnen sich, im Vergleich zu den meisten anderen Naturgefahren, durch einen diffusen und schwer zu bestimmenden Start- und Endzeitpunkt aus (*creeping onset*). Ihre Auswirkungen steigern bzw. akkumulieren sich langsam über längere Zeiträume und bestehen oft noch Jahre nach Beendigung des Ereignisses fort (Wilhite, 2000; Wilhite und Vanyarkho, 2000; Mishra und Singh, 2010). Dürren entstehen als Folge einer natürlichen Niederschlagsreduktion über einen Zeitraum, der in der Regel mehrere Monate beträgt. Zusätzlich tragen andere klimatische Faktoren, wie hohe Lufttemperaturen, starke Winde und eine geringe Luftfeuchtigkeit zur Schwere des Ereignisses bei und gehen häufig damit einher (Wilhite, 2000). Weiterhin haben das zeitliche Auftreten im Jahr, z.B. in Bezug zur Vegetationsperiode, sowie die Anzahl und Intensität der Niederschlagsereignisse einen entscheidenden Einfluss darauf, ob und wie intensiv Auswirkungen ausfallen. Dürren unterscheiden sich untereinander in ihrer Intensität, Dauer und räumlichen Ausdehnung (Wilhite, 2000). Es ist daher schwierig den Begriff Dürre abzugrenzen. Dieses Problem einer einheitlichen Definition, aufgrund der genannten Charakteristiken, erkannte schon Tannehill, 1947:

“We have no good definition of drought. We may say truthfully that we scarcely know a drought when we see one. We welcome the first clear day after a rainy spell. Rainless days continue for a time and we are pleased to have a long spell of such fine weather. It keeps on and we are a little worried. A few days more and we are really in trouble. The first rainless day in a spell of fine weather contributes as much to a drought as the last, but no one knows how serious it will be until the last dry day is gone and the rains have come again . . . we are not sure about it until the crops have withered and died.”

Der Bedarf einer einheitlichen und universellen Definition für Dürre sowie die damit einhergehende Problematik wurde mehrfach in der Literatur diskutiert (z.B. Wilhite und Glantz, 1985; Lloyd-Hughes, 2014). Unterschiede in hydrometeorologischen Größen sowie sozioökonomischen Faktoren (z.B. Wasserbedarf) in verschiedenen Regionen weltweit erweisen sich dabei als Hindernis (Mishra und

Singh, 2010). Wilhite und Glantz (1985) unterscheiden zwischen konzeptionellen Definitionen, die eine relative Beschreibung des Ereignisses darstellen (enzyklopädisch) und operativen Definitionen, welche versuchen, Beginn, Schwere und Ende einer Dürreperiode festzulegen. Wilhite (2000) hält eine universelle Definition von Dürre für unrealistisch, da die Auswirkungen von Dürre entscheidend sind und somit Definitionen auswirkungs- bzw. anwendungsbezogen sein sollten. Dürren werden allgemein in vier Klassen eingeteilt (Wilhite und Glantz, 1985; Wilhite, 2000; Mishra und Singh, 2010):

- Eine **meteorologische Dürre** bezeichnet einen Niederschlagsmangel in einer Region über eine gewisse Zeitspanne in Bezug zu langjährigen Niederschlagsmitteln. Sie sind das erste Dürresignal und unterscheiden sich vor allem in Intensität und Dauer. Es ist entscheidend, zwischen Regionen zu differenzieren, da die atmosphärischen Bedingungen, welche in Niederschlagsmangel resultieren, vom jeweiligen klimatischen Regime anhängen.
- Eine **landwirtschaftliche Dürre** ist eine Periode mit unterdurchschnittlicher Bodenfeuchte und führt somit zu einem Mangel an pflanzenverfügbarem Wasser. In der Regel sind Auswirkungen meteorologischer Dürren zuerst in der Landwirtschaft zu spüren. Gleichzeitig kann diese Form der Dürre mit dem Wiedereinsetzen von Niederschlägen ein abruptes Ende aufweisen.
- Eine **hydrologische Dürre** definiert eine Periode des Wassermangels in Oberflächengewässern und Reservoirs. Häufig treten diese zeitversetzt zu meteorologischen Dürren auf, da Niederschlagsdefizite in Oberflächengewässern durch das Grundwasser gepuffert werden können (Stahl, 2001). Die Geologie und Topologie einer Region kann das Entstehen hydrologischer Dürren entscheidend beeinflussen.
- Eine **sozioökonomische Dürre** bezeichnet unzureichende Verfügbarkeit von Wasser für die bestehende Nachfrage durch menschliche Aktivitäten. Van Loon et al. (2016) weisen darauf hin, dass der Begriff im Gegensatz zu den ersten drei Definitionen keine Dürre im physikalischen Sinne (Wassermangel) beschreibt, sondern sich auf die Auswirkungen von (physikalischen) Dürren auf sozioökonomische Systeme bezieht. Diese werden im Folgenden noch genauer erläutert.

Das Konzept der Dürreausbreitung (Abbildung 1) geht davon aus, dass meteorologische Dürren, abhängig von diversen Einzugsgebietseigenschaften wie Geologie und Vegetation, landwirtschaftliche und hydrologische Dürren zur Folge haben können, (van Loon et al., 2016). Eine meteorologische Dürre muss jedoch nicht zwangsweise eine landwirtschaftliche Dürre bedingen (Bachmair et al., 2018). Klima induzierte Dürren können durch menschliche Einflüsse (z.B. Landnutzung, Bewässerung, Dammbau, Wasserentnahme) zusätzlich verstärkt, vermindert oder aber gänzlich hervorgerufen werden (Mishra und Singh, 2010). Van Loon et al. (2016) führen deshalb zusätzlich den Terminus „menschlich-verursachte Dürre“ (*human-induced drought*) ein. Mishra und Singh (2010) schlagen weiterhin vor, den Begriff der „Grundwasserdürren“ in das Klassifikationsschema aufzunehmen: Grundwasserdürren entstehen durch eine verminderte Grundwasserneubildung und dadurch induzierte

absinkende Grundwasserspiegel. Da Grundwassersysteme deutlich langsamer auf Veränderungen reagieren, treten diese Dürren in Zeitskalen von Monaten bis Jahre auf. Anthropogene Grundwasserentnahmen oder Übernutzung können ebenfalls Grundwasserdürren hervorrufen (van Lanen und Peters, 2000). Lloyd-Hughes (2014) folgert, dass eine universelle Dürredefinition Bezug auf den Wasserbedarf, die Wasserversorgung und das Wassermanagement in der Region nehmen müsste und dass es keine universelle, sinnvolle Methode gibt, Dürre zu definieren, welche sich für alle Umstände und Nutzer eignet.




Abbildung 1: Konzept der Dürreausbreitung nach van Loon et al. (2016). Durch natürliche Klimavariabilität induzierte Dürren (meteorologisch, landwirtschaftlich und hydrologisch) können zusätzlich durch menschlichen Einfluss verstärkt oder abgeschwächt werden und haben sowohl in Umwelt- als auch in sozioökonomischen Bereichen Auswirkungen.

Einige weitere Terminologien, welche häufig mit dem Begriff Dürre verwechselt werden, sind in van Loon et al. (2016) zusammengefasst:

- **Aridität** bezeichnet eine permanente Klimateigenschaft, wenn der langjährige Niederschlag weit unter der langjährigen potentiellen Verdunstung liegt.
- **Wasserknappheit** (*scarcity*) ist ein langanhaltendes Ungleichgewicht zwischen Wassernachfrage und -versorgung. Sie tritt auf, wenn eine hohe durchschnittliche Nachfrage einer geringen Verfügbarkeit und/oder strukturellen Problemen der Wasserversorgung gegenüber steht.
- **Wasserstress** (*shortage/stress*) ist der akute Wassermangel im sozialen, wirtschaftlichen oder ökologischen Bereich, der durch eine geringere Versorgung als Nachfrage hervorgerufen wird.

- Eine **Hitzewelle** umfasst eine kürzere Zeitspanne als eine Dürre, meist ca. eine Woche (Mishra und Singh, 2010).

Eine große Herausforderung für die Dürreforschung bleibt die Komplexität der Auswirkungen von Dürren (Lackstrom et al., 2013). Auswirkungen steigern und akkumulieren sich mit der Zeit, wirken verglichen mit anderen Naturgefahren wie Hochwässern oder Wirbelstürmen selten strukturell (Schäden an Bauwerken) und breiten sich über große geographische Bereiche aus. Zudem sind sie langanhaltend und oftmals noch Jahre nachdem das eigentliche Dürreereignis vergangen ist, zu beobachten. All diese Faktoren machen sie schwer zu quantifizieren (Wilhite, 2000; Wilhite und Vanyarkho, 2000; Mishra und Singh, 2010; Lackstrom et al., 2013; Bachmair et al., 2015; van Loon et al., 2016). Entscheidend ist, dass Auswirkungen von Dürre kein rein natürliches Phänomen sind, sondern zusätzlich durch das Zusammenspiel zwischen dem Naturereignis (Niederschlagsdefizite aufgrund natürlicher Klimavariabilität) und der Nachfrage von Wasserressourcen durch menschlich genutzte Systeme bedingt sind (Wilhite und Vanyarkho, 2000). Während Niederschlagsdefizite vergleichsweise leicht zu quantifizieren sind, ist das Verständnis über die gesamte Bandbreite der Auswirkungen bis heute begrenzt (Lackstrom et al., 2013).

Allgemein lassen sich Auswirkungen als negative Folgen von Dürrebedingungen im ökonomischen, sozialen und ökologischen Bereich definieren (Knutson et al., 1998). Betroffen sind eine Vielzahl an Sektoren: Landwirtschaft, Wasserversorgung, Forstwirtschaft, Industrie, Energiegewinnung, Gesundheit, aquatische Ökologie etc. (Stahl et al., 2016). Die Vielfalt erklärt sich durch die Abhängigkeit von Wasser in vielen Bereichen der Produktion von Gütern oder der Bereitstellung von Dienstleistungen (Wilhite, 2000). Differenziert wird zwischen direkten Auswirkungen, z.B. Ernteverluste in der Landwirtschaft, eine verminderte forstliche Produktion oder dem Absinken von Reservoir-Speichern und indirekten Auswirkungen, z.B. eine erhöhte Sterblichkeit von Vieh oder eine gesteigerte Waldbrandgefahr (Knutson et al., 1998; Wilhite und Vanyarkho, 2000; van Loon et al., 2016). Je weiter die Auswirkung von der Ursache entfernt ist, desto komplexer ist der Zusammenhang zwischen dem Dürreereignis und der Auswirkung. Indirekte Auswirkungen werden daher häufig bei der Bewertung von Dürrezuständen nicht berücksichtigt (Lackstrom et al., 2013). Aus diesem Grund sind Informationen über Auswirkungen oftmals auf landwirtschaftliche Erträge und finanzielle Auswirkungen begrenzt: Diese sind direkter und einfacher zu beobachten (Lackstrom et al., 2013; Bachmair et al., 2016a), die Folgen von Dürre sind jedoch weit vielfältiger und komplexer als Ertragsmengen, da sie viele ökonomische und soziale Lebensbereiche sowie verschiedene Ökosysteme betreffen (Stahl et al., 2012). Die Überlagerung mehrerer Extremereignisse, zeitlich verzögerte Effekte und Saisonalität tragen zusätzlich zur Komplexität der Auswirkungen bei (Stagge et al., 2015).

1.2 Klimatologie Deutschlands und der Einfluss des Klimawandels

Es gilt als äußerst wahrscheinlich, dass sich Dürren als Folge des Klimawandels in der mediterranen und zentraleuropäischen Region weiter intensivieren werden (IPCC, 2012). Die wesentlichen Ergebnisse der beobachteten Änderungen extremer Temperaturereignisse auf globaler und europäischer Ebene sind in einem Sonderbericht des IPCC (2012) sowie dem fünften Sachzustandsberichts des IPCC zusammengefasst (Hartmann et al., 2013). Es wird unter anderem vermerkt, dass die dekadische durchschnittliche Oberflächentemperatur in Europa zwischen 2002 – 2011 um $1.3\text{ °C} \pm 0.11\text{ °C}$ über der Durchschnittstemperatur von 1850 – 1899 lag (Hartmann et al., 2013; IPCC, 2014). Insgesamt hat sich die Oberflächentemperatur innerhalb der letzten 140 Jahre um $0,95\text{ °C}$ in Europa erhöht. Die Hälfte der Erwärmung fand hierbei in der letzten 30 – 40 Jahren statt. Bis zum Ende des Jahrhunderts sagen Klimaprojektionen je nach Modell eine durchschnittliche Erwärmung von $2.2\text{ – }5.3\text{ °C}$ für Europa voraus (Christensen et al., 2007). Weiterhin ist eine Zunahme extremer Temperaturereignisse und Hitzewellen seit 1950 zu beobachten. Mehrere Autoren vermuten deswegen eine gesteigerte Auftretswahrscheinlichkeit extrem trockener und heißer Sommer wie im Jahr 2003 (Meehl und Tebaldi, 2004; IPCC, 2012; Hartmann et al., 2013). Diese Hypothese hat sich in Europa in den letzten Jahren (z.B. 2015, 2018, 2019) bestätigt. Innerhalb der letzten Jahrzehnte waren verschiedene Bereiche in Europa mehrfach von Dürren betroffen: 1976 (Nord- und Westeuropa), 1989 (weite Teile Europas), 1991 (weite Teile Europas), 2003 (weite Teile Europas, verbunden mit einer starken Hitzewelle), 2010 (Osteuropa), 2011 (Mittel-, Ost- und Südosteuropa), 2015 (Mittel- und Osteuropa), 2018 (Nord- und Zentraleuropa) und 2019 (Teile Nord-, Zentral- und Westeuropas) (Mishra und Singh, 2010; Hoy et al., 2017; Meinert et al., 2019).

Eine umfangreiche Zusammenfassung verschiedener Studien und Analysen über die Auswirkungen des Klimawandels in Deutschland sowie zukünftige Modellprojektionen findet sich in Brasseur et al. (2017). Das Klima in Deutschland zählt zu den kühlgemäßigten Klimazonen, mit milden Wintern und gemäßigt warmen Sommern, und befindet sich im Übergang vom westeuropäischen Maritimklima zum kontinentalen Klima Osteuropas. Die Jahresdurchschnittstemperatur der Luft beträgt $8,2\text{ °C}$ im langjährigen Mittel von 1961 – 1990 (DWD, 2019). Die Küstenregionen und der Westen Deutschlands sind aufgrund ihrer Nähe zu den Meeren weniger gefährdet als Ost- und Süddeutschland. Im Osten herrscht ein kontinentaleres Klima, im Süden treten Hitzewellen aufgrund heißer südlicher Winde häufiger auf (Brasseur et al., 2017). Extreme Jahre in der jüngeren Vergangenheit waren die Hitzewelle Anfang August 1992 in Ostdeutschland, die Hitzewelle im Jahr 2003, das Frühjahr 2011 (Brasseur et al., 2017) und der Sommer 2015 (Hoy et al., 2017). Das Jahr 2018 war in Deutschland im Mittel das wärmste Jahr seit Beginn der Wetteraufzeichnungen und gleichzeitig ungewöhnlich trocken (mittleres Niederschlagsdefizit von 200 mm). Der Juni 2019 war der wärmste seit Beginn der Wetteraufzeichnungen (Meinert et al., 2019).

Die Auswertung der Resultate verschiedener Klimaprojektionen für Deutschland ergab unter anderem, dass die Anzahl der meteorologischen Sommertage (Tageshöchsttemperatur $\geq 25^{\circ}\text{C}$) in Deutschland vermutlich deutlich zunehmen wird: In einige Regionen Südwestdeutschlands könnte jeder zweite Tag zwischen April-September ein meteorologischer Sommertag werden. Die erwartete Zunahme im Nordwesten liegt bei ca. 10 Sommertage pro Jahr, im Südosten bei über 40 und in der Alpenregion bei 11-24 (Brasseur et al., 2017). Klimaprojektionen zur Zunahme von Hitzewellen während der Sommermonaten sagen bis Ende des 21. Jahrhunderts eine 6 – 18-fache Zunahme voraus, die in den Alpenregionen sogar noch höher liegen könnte (Brasseur et al., 2017). Die Aufttrittswahrscheinlichkeit der (derzeit nur ca. einmal pro Jahr) beobachteten Tageshöchsttemperaturen dürfte stark ansteigen und könnte sich bis zum Ende des 21. Jahrhunderts, insbesondere in den Sommermonaten, fast verzehnfachen (Brasseur et al., 2017). Das Umweltbundesamt geht davon aus, dass bis Ende des 21. Jahrhunderts die mittlere Erwärmung in Deutschland zwischen $2,5^{\circ}\text{C}$ und $3,5^{\circ}\text{C}$ betragen wird. Diese Erwärmung wird saisonal und regional unterschiedlich stark ausgeprägt sein: am stärksten dürfte der Süden und Südosten Deutschlands im Winter betroffen sein. Die Projektionen sagen für diese Regionen eine Erwärmungen von mehr als 4°C im Vergleich zur Klimanormalperiode 1961 – 1990 voraus (UBA, 2006). Bis heute waren neun der zehn wärmsten Jahre seit Beginn der Wetteraufzeichnungen 1881 nach dem Jahre 2000, sechs von ihnen sogar nach 2010 (2018: $10,5^{\circ}\text{C}$; 2014: $10,3^{\circ}\text{C}$; 2015, 2007, 2000: $9,9^{\circ}\text{C}$; 1994: $9,7^{\circ}\text{C}$; 2017, 2011, 2002: $9,6^{\circ}\text{C}$; 2016, 2008: $9,5^{\circ}\text{C}$) (DWD, 2019). Insgesamt ist zukünftig eine höhere Klimavariabilität zu erwarten, wobei vor allem besonders starke Extreme öfter auftreten werden. Dies betrifft alle Jahreszeiten und alle Regionen (Deutschländer und Dalelane, 2012; Jacob et al., 2014; Brasseur et al., 2017).

In Deutschland fallen durchschnittlich 789 mm Niederschlag pro Jahr. Die höchsten jährlichen Niederschlagssummen von $>2000\text{ mm}$ fallen im Alpenraum und den Höhenlagen der Mittelgebirge. Die niederschlagsärmsten Regionen liegen in der Magdeburger Börde sowie im Thüringer Becken mit $<500\text{ mm}$ pro Jahr (Brasseur et al., 2017). Im Westen fällt tendenziell mehr Niederschlag als im Nordosten, da westliche Winde ganzjährig feuchte Luftmassen vom Atlantik bringen. Seit 1881 haben die Niederschläge um 10,2% im Vergleich zum langjährigen Mittel von 1961 – 1990 zugenommen, was vor allem durch eine Zunahme der winterlichen Starkniederschläge (+26%) bedingt ist. Im Vergleich dazu haben die Niederschlagssummen der Sommermonate im Mittel leicht abgenommen. Durch die hohe räumliche und zeitliche Variabilität der Niederschläge fallen die Trends jedoch je nach Region sehr unterschiedlich aus: Die stärkste Abnahme ergibt sich für die Mitte Deutschlands, den äußersten Westen und einige Küstenregionen, während die Trendrichtung in Sachsen uneinheitlich und von geringer statistischer Signifikanz ist. Positive Trends ergeben sich für einige Messstationen in Bayern und Baden-Württemberg (Brasseur et al., 2017). Für Teile Ostdeutschlands sagen Klimaprojektionen eine Zunahme sommerlicher Wasserknappheit voraus, was in Kombination mit der Verringerung der mittleren Sommerniederschläge die Entwicklung von Dürren begünstigt (Jacob et al., 2014). Die Zukunftsprojektionen der erwarteten Niederschläge sind sehr unsicherheitsbehaftet und unterscheiden

sich zum Teil erheblich je nach Klimamodell, Realisierung und Emissionsszenario (Brasseur et al., 2017).

Der folgende Abschnitt befasst sich intensiver mit den verschiedenen direkten und indirekten Dürreauswirkungen im forstlichen Bereich, welche für diese Arbeit von Interesse sind.

1.3 Dürreauswirkungen im Forst

Klimatischer Stress in Form von Hitze und Dürre beeinflusst negativ die Baumvitalität und Waldgesundheit (Boisvenue und Running, 2006). Langanhaltende Wasserdefizite können zur Abnahme der Waldproduktivität (Ciais et al., 2005) sowie zu einer erhöhten Baumsterblichkeit bis hin zu großflächigem Absterben der Vegetation in verschiedenen Regionen der Welt führen (Allen et al., 2010; Adams et al., 2012; Trugman et al., 2018). Die klimatischen und ökologischen Folgeschäden können weitreichend sein: Durch vermehrtes Baumsterben kann es zu einer reduzierten photosynthetischen CO₂-Aufnahme der Ökosysteme kommen. Ein verminderter Blattflächenindex erhöht die Einstrahlung auf die Bodenoberfläche und beeinflusst dadurch Bodenprozesse, Nährstoffkreisläufe, mykorrhizale Aktivität, Erosion, Transpiration und Boden Evaporation. Des Weiteren verändert sich der Albedo und der Land – Atmosphäre Energieaustausch und wirkt sich somit das regionale Klima aus (McDowell et al., 2008). Durch ein großflächiges Baumsterben können Regionen innerhalb weniger Jahre radikal verändern werden, was weitreichende Auswirkungen auf die Ökosystemstruktur und Funktion zur Folge hat. Im Vergleich dazu kann es durch den Einfluss des Klimawandels zu einer langfristigen (Jahrzehnte bis Jahrtausende) Veränderung der Spezieszusammensetzung kommen (McDowell et al., 2008).

McDowell et al. (2008) unterscheiden zwischen drei Hauptmechanismen, die dürreinduziertes Baumsterben verursachen können: Das Versagen der hydraulischen Leitfähigkeit, der Tod durch Kohlenstoffmangel sowie zusätzlich der Einfluss biotischer Schadfaktoren. Die Intensität und Dauer des Wassermangels beeinflussen die Relevanz der Prozesse. Die beiden erstgenannten Mechanismen beschreiben zwei unterschiedliche Strategien der stomatalen Wasserhaushaltsregulierung von Pflanzen als Reaktion auf ein vermindertes Bodenwasserpotential und eine gesteigerte Evapotranspiration (Tardieu und Simonneau, 1998). Beim Versagen der hydraulischen Leitfähigkeit führt eine verminderte Bodenwasserverfügbarkeit in Kombination mit einer hohen Evapotranspiration zu einem gestörten Wasserfluss in der Pflanze. Dies kann schlussendlich dazu führen, dass Luft in das Xylem und die Rhizosphäre eindringt (Kavitation oder Xylemembolie). Durch Kavitation wird der Wasserfluss in den Pflanzen gestoppt und diese irreversibel geschädigt. Die Pflanzen verdörren und es kommt zum Zelltod (McDowell et al., 2008). Dies passiert vor allem bei sogenannten anisohydrischen Arten. Diese sind zwar generell dürrerotoleranter, verfügen jedoch über eine geringere Kontrolle der stomatalen Leitfähigkeit während Dürreereignissen. Weiterhin sind vor allem Jungbäume und Setzlinge aufgrund ihres geringeren Wurzelvolumens oder sehr großen Bäumen mit langen Transportwegen betroffen (McDowell et al., 2008; McDowell et al., 2011). Im Gegensatz dazu versuchen isohydrische Arten durch

Stomataschließung ihre Transpiration zu reduzieren, um somit das Versagen der hydraulischen Leitfähigkeit zu vermeiden. Dies führt zu einer geringeren Photosyntheseleistung und kann schließlich zum „Verhungern“ der Pflanze führen, da der Metabolismus aufgrund von Kohlenstoffmangel nicht mehr ausreichend versorgt wird (McDowell et al., 2008; McDowell et al., 2011). Der Kohlenstoffmangel verursacht meist kein direktes Baumsterben während des Dürreereignisses (Anderegg et al., 2012; Adams et al., 2017), sondern wirkt sich langfristig auf das Baumwachstum nach dem Dürreereignis bis hin zum Baumsterben aus (Trugman et al., 2018).

Der Befall von Bäumen durch biotische Schadfaktoren, wie Insekten oder Pathogenen, ist eine weitreichende, indirekte Auswirkung von Dürre auf die Waldgesundheit. Diese Auswirkungen zeigen sich häufig erst in den Folgejahren des Dürreereignisses (Bréda et al., 2006; Rouault et al., 2006; McDowell et al., 2008; Raffa et al., 2008). Der Befall wird bei geschwächten Bäumen durch die geringere Produktion sekundärer Metabolite (z.B. Resin) begünstigt, welche aufgrund der limitierten Kohlenstoffressourcen nicht mehr aufrechterhalten werden kann (Anderegg et al., 2015). Dieser Umstand begünstigt zum Beispiel den massiven Ausbruch des Borkenkäfers, dem größten biotischen Schadfaktor der nördlichen Hemisphäre (McDowell et al., 2011). Wärmere Temperaturen können ein gesteigertes Larvenwachstum und Überleben im Winter, eine erhöhte Anzahl an Generationen pro Jahr, stärkere Wachstumsraten von Populationen sowie eine größere geografische Ausbreitung begünstigen (Rouault et al., 2006; McDowell et al., 2008; Anderegg et al., 2015; Caldeira, 2019). Biotische Schadfaktoren können das Baumsterben sowohl wegen Kohlenstoffmangel als auch aufgrund hydraulischer Fehlfunktion verstärken und umgekehrt. Es gilt als unwahrscheinlich, dass Dürre für alle baumbefallenden Insekten in allen Regionen förderlich ist (McDowell et al., 2008). Es werden jedoch jene begünstigt, welche das stärkste Baumsterben zu verantworten haben. Der Ausbruch von Insekten ist zudem von den Eigenschaften der Wirtsbäume, wie z.B. Häufigkeit, Dichte, Größe, Physiologie und räumlicher Ausdehnung abhängig (Raffa et al., 2008).

Die in Deutschland verbreitetsten Baumarten zeigen unterschiedliche Reaktionen auf Dürre und Hitze und sind unterschiedlich anfällig gegenüber den erwarteten Klimaänderungen von Temperatur und Niederschlag (Kölling und Zimmermann, 2007). Buchen (*Fagus sylvatica*) sind bei ausreichender Nährstoff- und Wasserverfügbarkeit die dominierende Laubbaumart in Deutschland (Bohn und Gollub, 2007). Ihre hohe Schattentoleranz gibt Ihnen einen Wettbewerbsvorteil gegenüber anderen Baumarten, wie z.B. Eichen. In Deutschland verbreitete Eichen sind vor allem *Quercus robur* und *Quercus petraea*, welche in der Folge als *Quercus sp.* zusammengefasst werden. *Fagus* weisen eine höhere Dürresensitivität als *Quercus sp.* in Bezug auf Stamm- und Feinwurzelwachstum sowie Photosyntheseraten auf (Leuschner et al., 2001). *Quercus sp.* wächst unter kontinentaleren Bedingungen als *Fagus* und ist somit im Allgemeinen an trockenere Bedingungen angepasst (Leuschner et al., 2001; Bréda et al., 2006). Dies ist durch eine unterschiedliche Physiologie bedingt: eine größere Wurzeltiefe macht *Quercus sp.* robuster gegenüber dürreinduzierter Xylemembolie (Cochard, 1992; Rosengren et

al., 2006). Die dominierende Nadelbaumart in Deutschland ist die gemeine Fichte (*Picea albies*). Sie ist ein Flachwurzler, da ein Großteil Ihrer Feinwurzeln in 20-25 cm Tiefe liegen (Rosengren et al., 2006). *Picea* wird in Deutschland aus forstwirtschaftlichen Gründen außerhalb Ihres natürlichen Verbreitungsgebiets angebaut. Dieses liegt in den trocken-kalten Klimaten der borealen Nadelwälder und den feucht-kalten Klimaten der alpinen Höhenwälder. Aufgrund dessen wird die Fichte in Klimaprojektionen als besonders gefährdet eingestuft (Kölling und Zimmermann, 2007). Dies ist vor allem durch den bereits erwähnten, massiven Befall von *Picea* durch den Borkenkäfer bedingt. Der Befall wird durch die projezierten Temperaturerhöhungen häufiger auftreten. Die zweithäufigste Nadelbaumart in Deutschland ist die Waldkiefer (*Pinus sylvestris*). Sie wird im Allgemeinen als dürrerotolerant beschrieben, gilt jedoch als anfällig für Xylemembolie unter Dürrebedingungen (Cochard, 1992; Taeger et al., 2013).

Das allgemeine Verständnis der physiologischen Prozesse, welche ein Baumsterben als Reaktion auf Dürreereignisse verursachen können, ist immer noch limitiert. Ein umfassenderes Wissen über Kohlenstoffbilanzierung, Kohlenstoffspeicher und den Pflanze-Wasser Haushalt wäre nötig, um fundierte Vorhersagen über Dürrereaktionen von Pflanzen treffen zu können (McDowell et al., 2011; Camarero et al., 2015). Aufgrund der sehr unterschiedlichen Reaktionen von Pflanzen auf Dürre könnte es sich als schwierig erweisen, generalisierte Aussagen über Dürrereaktionen zu treffen (Ryan, 2011).

Neben der Intensität einer Dürre ist vor allem das zeitliche Auftreten im Jahresverlauf einer der entscheidenden Faktoren, wie stark und welche spezifischen Auswirkungen im forstlichen Bereich auftreten (Taeger et al., 2013; Caldeira, 2019). Ein Dürreereignis während des Frühjahrs oder Frühsommers beeinflusst das Triebwachstum desselben Jahres, während ein Dürreereignis im Spätsommer vor allem das Triebwachstum des Folgejahres beeinflussen kann (Bréda et al., 2006). Des Weiteren sind, je nach zeitlichem Auftreten des Dürreereignisses im Jahresverlauf, unterschiedliche Wachstumsphasen der Bäume, z.B. Triebwachstum oder Wurzelwachstum, betroffen. Zusätzlich zum Zeitpunkt des Dürreereignisses sind Prädisposition und die Bedingungen während der Erholungsphase nach dem Dürreereignis für die Reaktion des Baumwachstums entscheidend (Taeger et al., 2013). Eine erhöhte Klimavariabilität mit mehr Extremereignissen könnte das Zeitfenster von Dürren verschieben, sodass Trockenstress bereits zu Beginn der Vegetationsperioden auftreten könnte (Anderegg et al., 2013; Caldeira, 2019). Die kann zu einer verminderten Funktionalität und Erholungsfähigkeit der Bäume von abiotischem und biotischem Stress führen (Anderegg et al., 2013; Forner et al., 2018). Forner et al. (2018) identifizieren den Einfluss des Zeitpunkts von Dürre bei einigen Arten (besonders bei laubabwerfenden) als stärker als den der Dürreintensität. Für die mit langen Umtriebszeiten kalkulierende Forstwirtschaft stellen Ausmaß und Geschwindigkeit des erwarteten Klimawandels eine besondere Herausforderung dar. Die projizierten wärmeren und niederschlagsreicheren Winter begünstigen das Auftreten von Pilzerkrankungen, die trockeneren Sommer die Ausbreitung von

Schadinsekten. Des Weiteren kann der frühere Beginn der Vegetationsperiode zu einem gesteigerten Spätfrostisiko führen (Sutmöller et al., 2008).

Eine weitere, indirekte Auswirkung von Dürre im Forstsektor ist eine gesteigerte Waldbrandgefahr. Aufgrund der sandigeren Böden besteht im Nordosten Deutschlands eine höhere Waldbrandgefahr als in anderen Regionen des Landes (Brasseur et al., 2017). Eine stark fragmentierte Landschaft, das gemäßigte Klima sowie ein effektives Waldbrand-Monitoring bewirken, dass bisher nur in extrem trockenen Jahren Waldbrände aufgetreten sind. Die zunehmende Klimavariabilität bedingt einen Anstieg der Tage mit hoher Waldbrandstufe (Wittich et al. 2011) und ein kürzeres Intervall zwischen diesen Tagen (Wastl et al. 2012). Obwohl die klimatisch bedingte Waldbrandgefahr in Deutschland steigt, kompensieren Sicherheitsmaßnahmen diese derzeit noch. Projektionen der Waldbrandgefahr beinhalten nur die klimatische Gefährdung, jedoch nicht die Interaktion zwischen Bestandsstruktur, menschlicher Nutzung und Feuer, welche Feuereffekte verstärken oder abschwächen können (Brasseur et al., 2017). Auf das Risiko durch Waldbrände wird in dieser Arbeit nicht näher eingegangen.

1.4 Stand des Wissens

Nachdem die vorherigen Abschnitte allgemein das Naturphänomen Dürre, die Auswirkungen des Klimawandels und die spezifischen Auswirkungen von Dürre im Forst beschrieben haben, widmen sich der folgende Abschnitt und seine Unterkapitel dem aktuellen Stand des Wissens der Dürreisikoanalyse mittels Dürreindices und textbasierten Wirkungsberichten. Dieser methodische Ansatz wird im ersten Teil der Arbeit verwendet. Des Weiteren wird auf die Verwendung von Kronenentlaubungsdaten als Indikator für die Waldgesundheit in vergangenen Studien eingegangen, da diese Methode im zweiten Teil der Arbeit angewendet wird.

1.4.1 Vulnerabilitäts- und Risikoanalyse

Das Dürreisiko einer Region setzt sich aus der Summe von Gefahr und Vulnerabilität zusammen: Die Gefahr (*hazard*) bezeichnet die Wahrscheinlichkeit des Auftretens eines Naturereignisses (z.B. Dürre), welches negative Auswirkungen auf Mensch und Umwelt hat. Dieses kann Unterschiede in Ausdehnung und Dauer sowie Intensität und Schwere haben (Wilhite, 2000; Mishra und Singh, 2010). Gegen Frequenz und Schwere meteorologischer Dürren kann generell wenig unternommen werden. Diese Komponente wird meistens über statistische Analysen eines Dürreindex oder mehrerer Dürreindices berechnet (Blauhut et al., 2016). Die Charakteristik von Dürreindices wird im folgenden Abschnitt genauer erläutert. Ob ein Dürreereignis negative ökologische, soziale und ökonomische Folgen hat oder nicht, hängt entscheidend von der Vulnerabilität der Region bzw. betroffenen Sektoren ab (Knutson et al., 1998; Bachmair et al., 2015; van Loon et al., 2016). Die Vulnerabilität oder Anfälligkeit eines Systems wird durch soziale Komponenten wie Entwicklungen in Technologie, Politik, Bevölkerung (steigende Nachfrage), Sozialverhalten etc. beeinflusst. Diese Faktoren sind dynamisch, weshalb auch

die Vulnerabilität einer betrachteten Region zeitlich variabel ist. Dürren der gleichen Intensität, Dauer und Ausbreitung können unterschiedliche Auswirkungen haben, wenn sich die gesellschaftlichen Bedingungen verändert haben (Wilhite, 2000). Durch menschliches Eingreifen kann die Vulnerabilität und somit die Schwere der Auswirkungen von Dürre in einer Region gesenkt werden. Ein kontinuierliches Monitoring und Dürre-Frühwarnsysteme können das Risiko mindern und die Bereitschaft einer Region auf zukünftige Ereignisse verbessern (Wilhite, 2000; Bachmair et al., 2015). Die Abschätzung der Vulnerabilität einer Region bildet das Rahmengerüst, um die eigentliche Ursache von Dürreauswirkungen zu identifizieren. Laut Knutson et al. (1998) misst die Vulnerabilität einen Zustand, unter dem Auswirkungen auftreten können, wenn eine bestimmte Schwere von Dürre auftritt. Die Abschätzung der Vulnerabilität kann grundsätzlich über zwei Ansätze geschehen: Zum einen über die subjektive Gewichtung von verschiedenen Vulnerabilitätsfaktoren (*factor approach*) (Fu et al., 2013; Blauhut et al., 2015). Eine Kombination verschiedener Faktoren aus den Bereichen Exposition (geografischer Anteil, der von Dürre betroffen ist), Sensitivität (Lebensgrundlage der Region) und Anpassungsfähigkeit (verfügbare Mittel zur Risikoreduzierung) charakterisiert die Vulnerabilität einer Region (Blauhut et al., 2016). Hierfür sind jedoch häufig explizite und schwer zu erhaltende Informationen über physikalische, ökologische und sozioökonomische Parameter erforderlich (Blauhut et al., 2015). Zum anderen kann eine Bewertung der Vulnerabilität über die Auswirkungen von Dürre erfolgen (*impact approach*). Hierfür werden Informationen über vergangene Auswirkungen von Dürre als einen Prädiktor für die Vulnerabilität verwendet. Das Dürreerisiko beschreibt dann die Auftretenswahrscheinlichkeit einer bestimmten Art von Dürreauswirkung (Blauhut et al., 2016). Nur wenige Forschungen der vergangenen Jahre verfolgen den zuletzt beschriebenen Ansatz und berücksichtigen vergangenen Berichte über Dürreauswirkungen bzw. validieren ihre Risikoanalysen damit, obwohl die Berichte ein Indikator für Vulnerabilität einer Region sind (Knutson et al., 1998; Blauhut et al., 2016). Ein Literaturrückblick über die Verwendung der verschiedenen Ansätze zur Beurteilung von Vulnerabilität ist in González Tánago et al. (2016) gegeben.

1.4.2 Dürreindices

Die Schwere eines Dürreereignisses (*hazard*) lässt sich durch eine Vielzahl an Variablen beschreiben, die sich grundlegend in die zwei Gruppen „Dürreindikatoren“ und „Dürreindices“ aufteilen lassen (Heim, 2002; Zargar et al., 2011; Blauhut et al., 2016): Dürreindikatoren sind quantitative Messungen direkter Aspekte der Dürre, z.B. Klimakonditionen, Vegetationszustand, Bodenfeuchte etc. Sie messen also ein Wasserdefizit und werden aus meteorologischen oder hydrologischen Daten abgeleitet. Dürreindices dienen der Quantifizierung der Schwere, Intensität und Dauer von Dürreereignissen (Mishra und Singh, 2010). Hierfür werden Daten eines oder mehrerer Dürreindikatoren in einen numerischen Wert zusammengefasst (Zargar et al., 2011). Dürreindices beschreiben somit eine Trockenheitsanomalie. Die Schwere eines Dürreereignisses oder die Warnstufen von Dürrefrühwarnsystemen werden häufig über willkürliche Schwellenwerte der jeweiligen Dürreindices

festgelegt. Die Wahl dieser Schwellenwerte, welche potentielle Auswirkungen auf sozioökonomische und ökologische Systeme beschreiben sollen, ist oft dem (subjektiven) Urteil von Experten überlassen (Blauhut et al., 2016). Die große Anzahl an vorhandenen Indices (>100) (Zargar et al., 2011) unterstreicht die Schwierigkeit und Bedeutung einer objektiven Dürre Definition (Lloyd-Hughes, 2014). Trotz der Vielzahl an Indices fehlen häufig eindeutige Richtlinien, wie und wann diese Indices zu verwenden sind (Blauhut et al., 2015). Ein Grund dafür ist, dass viele Indices zwar generelle meteorologische Anomalien beschreiben, nur wenige jedoch unter der Zuhilfenahme von beobachteten Dürreauswirkungsdaten entwickelt bzw. gegen diese getestet wurden (Blauhut et al., 2015; Bachmair et al., 2016a). Somit werden bei großflächigen Studien im Bereich Dürremonitoring, Frühwarnsystemen, Planung und Richtlinienentwicklung die Dürreindices häufig willkürlich gewählt und stehen oftmals in keiner direkten Verbindung zu spezifischen Auswirkungen (Kallis, 2008; Stahl et al., 2016; Bachmair et al., 2016b). Die meisten Monitoring- und Frühwarnsysteme prognostizieren somit die meteorologische Dürregefahr liefern aber keine Informationen darüber, wann und wo ein Niederschlagsdefizit zu negativen Folgen führen kann (Bachmair et al., 2017).

1.4.3 Dürrerisikoanalysen anhand von Wirkungsberichten

Verschiedene Studien der letzten zwei Jahrzehnte bemängelten, dass viel Forschung zur meteorologischen Dürregefahr (*hazard*) betrieben wurde, jedoch zu wenig über die eigentlichen Auswirkungen von Dürre. Ein rein auf hydrometeorologischen Daten basierender naturwissenschaftlicher Ansatz wird als nicht mehr ausreichend angesehen, um die komplexen und umfangreichen Auswirkungen von Dürre auf Mensch und Umwelt zu erfassen (Kallis, 2008; Lackstrom et al., 2013). Bachmair et al. (2018) fordern einen Wechsel zu einem auf die Auswirkungen von Dürre fokussierten Dürre Monitoring- und Frühwarnsystem. Durch diesen Ansatz sollen Vulnerabilitäten durch erfolgreiches Dürremanagement gemindert werden und somit das Risiko vorausschauend verkleinert werden, anstatt rückwirkend auf die Auswirkungen von Dürre zu reagieren (Knutson et al., 1998; Wilhite et al., 2007; Mishra und Singh, 2010; van Loon et al., 2016; Bachmair et al., 2018). Dass die Forderungen nach Forschung in diesem Bereich nicht neu sind, zeigt eine Bemerkung von J. Lyons (damals Sekretär für Landwirtschaft und natürliche Ressourcen in den USA) aus dem Jahr 1994 auf einer Dürre Management Konferenz in Portland, Oregon:

„Wir müssen das unvermeidliche akzeptieren – das Dürren kommen und gehen werden – und dass ein (Dürremanagement) Ansatz gewählt werden muss, der versucht, die Auswirkungen von Dürre zu minimieren, wenn sie unvermeidlich auftritt“ (aus Knutson et al., 1998).

Dennoch bedürfen die Methoden, um den Zusammenhang zwischen physikalische Dürreindices und gesellschaftlichen Auswirkungen zu untersuchen, eines noch systematischeren Ansatzes und werden erst seit kurzen erforscht (van Loon et al., 2016). Einige Studien, welche das Dürrerisiko anhand von

textbasierten Wirkungsberichten in Deutschland und Europa analysierten, werden in der Folge vorgestellt.

Eine der ersten Studien, die den Zusammenhang zwischen meteorologischen Dürreindizes und qualitativen, textbasierten Dürreauswirkungsdaten untersuchte, stammt von Stagge et al. (2015). Die Autoren versuchten, das Dürrierisiko in fünf europäischen Ländern durch den funktionellen Zusammenhang zwischen meteorologischen Dürreindizes und textbasierten Auswirkungsdaten aus der *European Drought Impact report Inventory* (EDII – siehe Abschnitt 3.2.2.1) Datenbank zu beschreiben. Die Auswirkungsdaten wurden mittels logistischer Regression als Funktion von SPI (*Standardized Precipitation Index*) und SPEI (*Standardized Precipitation Evaporation Index*) modelliert. Der SPI beschreibt eine reine Niederschlagsanomalie während der SPEI zusätzlich die potentielle Evapotranspiration betrachtet und somit die klimatische Wasserbilanz berechnet. Die Autoren verglichen die Eignung verschiedener Akkumulationsperioden der Dürreindizes, um die Auswirkungen in vier verschiedenen Kategorien der EDII Datenbank (Landwirtschaft, Energie und Industrie, öffentliche Wasserversorgung und Süßwasserökosysteme) zu beschreiben. Die Akkumulationsperiode eines Index beschreibt dabei den betrachteten Zeitraum, über welchen die Trockenheitsanomalie betrachtet wird. Sie variiert in der Regel zwischen einem und 24 Monaten. Für jede Region und jede Auswirkungskategorie wurde auf monatlicher Basis ein binärer Datensatz (Auswirkung berichtet; Ja/Nein) aus den Auswirkungsdaten generiert. Die Autoren identifizierten die relevantesten Indices für jede Region und jeden Auswirkungsbereich, den Anteil erklärter Varianz der Auftrittswahrscheinlichkeit von Dürreauswirkungen durch die Dürreindizes sowie wiederkehrende Muster in den verschiedenen Regionen und Auswirkungsbereichen.

Blauhut et al. (2015) wandten diese Methodik erstmals auf europäischer Ebene an. Die Auftrittswahrscheinlichkeit von Dürreauswirkungen wurde als Funktion des SPEI für vier europäische Makroregionen mittels logistischer Regression untersucht. Die gewählten Regionen sind europäische Bereiche mit ähnlichem Klima: Nordosteuropa, Südosteuropa, Maritimeuropa sowie Westeuropa und die Mittelmeer Region. Die Autoren unterschieden zwischen den Auswirkungskategorien Landwirtschaft und Viehzucht, Energie und Industrie, öffentliche Wasserversorgung und Wasserqualität. Die Auswertung erfolgte auf jährlicher Basis mit binären Datensätzen. Das Ergebnis der Studie waren sektorenspezifische Dürrierisikokarten für die vier europäischen Makroregionen. 2016 wurde von den Autoren ein Hybridansatz gewählt, in dem die oben beschriebene Methodik mit einer traditionellen Vulnerabilitätsanalyse kombiniert wurde. Neben dem SPI und SPEI wurden auch kombinierte Dürreindizes des *European Drought Observatory* (EDO) und des Deutschen Dürremonitors verwendet, welche Bodenfeuchteanomalien und den Zustand der Vegetationsbedeckung beschreiben. Der europaweite Vulnerabilitätsindex, welcher als zusätzlicher Prädiktor in die Modellierung aufgenommen wurde, basierte auf 69 Vulnerabilitätsfaktoren und wurde nach De Stefano et al. (2015) erstellt.

Eine Formalisierung der Methodik sowie die Anwendung alternativer, statistischer Modelle wurde 2017 von Bachmair et al. durchgeführt. Für das Untersuchungsgebiet Südostengland wurde der funktionale Zusammenhang zwischen verschiedenen Akkumulationsperioden der Dürreindices SPI und SPEI sowie den EDII Auswirkungsdaten auf monatlicher Basis untersucht. Im Gegensatz zu den vorangegangenen Studien wurden die Auswirkungsdaten auf drei unterschiedliche Weisen betrachtet: als binärer Datensatz (Auswirkung im Monat m Ja/Nein), als Summe berichteter Auswirkungen pro Kategorie und Monat sowie als Summe berichteter Auswirkungen pro Subkategorie und Monat. Neben der logistischen Regression testeten die Autoren eine Null-korrigierte negativ-binomial Regression („*hurdle model*“) sowie ein „*random forest*“ (*ensemble regression tree*) Ansatz. Die beiden letztgenannten können im Gegensatz zur logistischen Regression auch die Gesamtanzahl an berichteten Auswirkungen vorhersagen und nicht nur auf binäre Datensätze angewandt werden. Sie fungieren somit als ein Messwert für die Schwere der Auswirkungen. Die Modellperformance wurde für die Gesamtheit der Auswirkungen als auch die Bereiche Wasserversorgung und Süßwasserökosysteme verglichen.

Im Jahr 2018 bemängelten Bachmair et al., dass viele Dürremonitore und Frühwarnsysteme für die Land- und Forstwirtschaft ausschließlich auf meteorologischen Dürreindices basieren und selten Informationen zum Vegetationszustand beinhalten. Aufgrund dessen untersuchten die Autoren den Zusammenhang zwischen verschiedenen Akkumulationsperioden von SPI und SPEI auf monatlicher Basis als Prädiktor und auf Fernerkundungsdaten basierenden Vegetationsindices (VIs) als Antwortvariable. Die Untersuchungen wurden sowohl für landwirtschaftliche als auch für forstliche Flächen durchgeführt. Des Weiteren wurden mittels schrittweiser linearer Regression diejenigen geografischen Parameter identifiziert, welche die räumlichen Korrelationsmuster zwischen lokalen meteorologischen Dürreindices und VIs am besten erklären. Die Korrelationsanalyse erfolgte auf europäischer NUTS-3 Ebene und ausschließlich für die Monate der Vegetationsperiode (Apr – Okt) für den Zeitraum von 2000 – 2015. Zu guter Letzt wurde in einem Fallbeispiel die Korrelation zwischen Maiserträgen und VIs in Deutschland untersucht und die Ergebnisse zweier VIs miteinander verglichen. Die Autoren identifizierten kurze Akkumulationsperioden von SPI und SPEI (2-4 Monate) als am besten geeignet, um Wasserstress bei Nutzpflanzen vorherzusagen. Für den Forstsektor hingegen weisen häufig längere Akkumulationsperioden den besseren Modellfit auf. Im Allgemeinen waren meteorologischen Dürreindices in südlichen und östlichen Regionen besser zur Vorhersage von Vegetationsstress geeignet als in mittleren und nördlichen Regionen Europas. Somit wird die Verwendung meteorologischer Indices zur Vorhersage von Dürreauswirkungen in Land- und Forstwirtschaft in kälteren und feuchteren Teilen Europas weniger empfohlen.

1.4.4 Kronenentlaubung als Zeiger für die Waldgesundheit

Die ‘*International Co-operative Programme on Assessment and Monitoring of Air pollution Effects on Forests*’ (ICP Forest) setzt sich die Überwachung der Waldgesundheit in Europa zum Hauptziel. Als repräsentativer Parameter für die Waldgesundheit gilt die Kronenentlaubung, welche den Nadel- oder

Blattverlust eines Baumes im Vergleich zu einem lokalen oder absoluten Referenzbaum beschreibt (Michel und Seidling, 2016). Dieser Parameter wird im sogenannten Level-I Monitoring einmal pro Jahr großflächig (min. 16 x 16 km Raster) in Europa erhoben. Eine ausführlichere Beschreibung der verwendeten Daten erfolgt in Abschnitt 3.2.2.2. Nur wenige Studien haben bis heute diese Level-I Daten verwendet, um den Bezug zwischen Kronenentlaubung und meteorologischen Dürreindizes zu untersuchen.

Eine der Studien, die Kronenentlaubung als Folge von Dürre in Deutschland untersucht, stammt von Seidling aus dem Jahr 2007. Der Autor untersuchte Zeitreihen der Level-I Kronenentlaubungsdaten von *Pinus sylvestris*, *Picea albies*, *Fagus sylvatica* und *Quercus sp.* für den Zeitraum von 1990 – 2004 und setzte diese in Zusammenhang mit klimatischen Dürrefaktoren. Auf monatlicher Basis waren durchschnittliche Lufttemperatur, Niederschlagssumme, Globalstrahlung und durchschnittliche Windgeschwindigkeit als klimatische Faktoren für alle Stände vorhanden, zusätzlich waren Informationen über das Standalter und weitere Standortspezifische Faktoren verfügbar. Der Autor identifizierte das Standalter als den wichtigsten Treiber der Kronenentlaubung für alle Arten. Als Reaktion auf die extremen Temperaturen im Jahr 2003 zeigten *Pinus*, *Picea* und *Fagus* einen erhöhten Blattverlust, meist mit einem zeitlichen Versatz von einem Jahr. Longitudinale Modelle, also räumlich-zeitliche Analysen von Zeitreihen, ergaben einen signifikanten Zusammenhang zwischen Kronenzustand und Abweichungen vom langjährigen Mittel für Temperatur, Niederschlag, Globalstrahlung und Windgeschwindigkeit. Nicht alle Resultate entsprachen der Trockenstresshypothese, was jedoch laut Autor aufgrund der heterogenen Stand- und Klimabedingungen in Deutschland auch nicht erwartet wurde.

Eine Studie aus den borealen Wäldern Finnlands stammt von Muukkonen et al. (2015). Da einige Gebiete anfälliger gegenüber sinkender Bodenfeuchte sind als andere, untersuchen die Autoren den Zusammenhang zwischen Level I Kronenentlaubungsdaten, einem modellierten Bodenwasserindex (SWI – absolut und relativ), sowie GIS-basierten Informationen über Vegetationsbedeckung und Hangneigung. Das Ziel der Studie war es, das räumliche und zeitliche Auftreten von Dürreauswirkungen zu untersuchen und eventuell anfällige Standorte zu identifizieren. Die Klima- und Bodenfaktoren mit dem größten Einfluss auf die Kronenentlaubung sind der Bodenwasserindex (relativ und absolut), der Flächenanteil an blankem Fels sowie die räumliche Lage an der Nord-Süd Achse.

Sousa-Silva et al. (2018) untersuchten die Bedeutung der Artenvielfalt für die Aufrechterhaltung der Waldgesundheit- und Vitalität. Dazu verwendeten sie ICP Forest Kronenentlaubungsdaten aus über 100 Ständen in Belgien. Untersucht wurde die zeitliche Variation der Kronenentlaubung von *Fagus sylvatica* (Rotbuche), *Quercus petraea* (Traubeneiche) und *Quercus robur* (Stieleiche) mittels *linear mixed effect models* (LMMs). Sie modellierten die Kronenentlaubung als Funktion des SPEI als Dürreindex sowie verschiedener Standortsfaktoren. Die Autoren beobachteten einen fortlaufenden Wandel von einem negativen zu einem positiven Zusammenhang zwischen Artenvielfalt und Waldgesundheit innerhalb der

letzten 25 Jahre. Sie kommen zu dem Schluss, dass eine höhere Artenvielfalt die Kronenentlaubung langfristig reduziert und diversere Wälder eine höhere Widerstandsfähigkeit gegenüber zukünftigem, klimainduziertem Stress haben.

Eine ähnliche Studie führten Iacopetti et al. im Jahr 2019 durch. Die Autoren untersuchten die Beziehung zwischen Kronenentlaubung und Vielfalt der Wälder in Italien, einem Land mit heterogenen klimatischen und edaphischen Bedingungen (Mediterran bis Alpin) und einer Vielzahl von Baumarten. Mittels *random forest* Analysen identifizierten sie geographische Lage, Baumart, Standalter und Struktur als relevanteste Faktoren für die Kronenentlaubung. Allerdings untersuchte diese Studie nicht speziell den Zusammenhang zwischen Kronenentlaubung und Dürreereignissen.

Eine weitere, aktuelle Studie stammt aus dem Jahr 2019 von Eickenscheidt et al.. Die Autoren verwenden *generalized additive mixed models* (GAMMs), um die räumlich-zeitlichen Trends der Kronenentlaubung der vier Hauptbaumarten (*Fagus*, *Picea*, *Pinus*, *Quercus sp.*) in Deutschland von 1990 – 2015 zu untersuchen. Laut den Autoren ist dies die erste Studie, die statistische Evaluierungen von räumlich-zeitlichen Trends der Kronenentlaubung für Gesamtdeutschland vornimmt. GAMMs haben den Vorteil, dass sie den räumlich-zeitlichen Trend der Daten berücksichtigen und mit unregelmäßigen Rasterdaten arbeiten können (Eickenscheidt et al., 2019). Die Modellierung erfolgte für die durchschnittliche Kronenentlaubung je Baumart und Stand. Des Weiteren analysierten die Autoren die Eignung verschiedener Raster-Auflösungen (8 x 8 km; 16 x 16 km) für die räumlich-zeitliche Modellierung, indem die Vorhersagefehler verglichen wurden. Sowohl die räumlich-zeitliche Komponente als auch das Standalter hatten einen signifikanten Effekt auf die Kronenentlaubung. Während das Standalter vornehmlich die Schwere der Kronenentlaubung bestimmte, waren Fluktuationen der Zeitreihen meist wetterbedingt. Der Einfluss des Standalters ist artenspezifisch (bei *Pinus* der geringste Einfluss, *Quercus sp.* am höchsten), generell nimmt die Kronenentlaubung jedoch mit zunehmendem Standalter zu. Die Autoren führen den artenspezifischen Zusammenhang zwischen Entlaubung und Alter auf den für die entsprechenden Arten typischen Bedarf an Licht, Bestandssituation, Bestandsentwicklung und Waldbewirtschaftung (Beschneiden, Ausdünnen, Fällen) zurück. Um verlässlich räumlich-zeitliche Trends zu schätzen und „Hotspots“ der Kronenentlaubung zu lokalisieren empfehlen die Autoren mindestens ein 8 x 8 km Raster-Gitter bei der Datenerhebung.

2 Problemstellung und Zielsetzung

Viele Regionen in Deutschland wurden in den letzten Jahren immer häufiger von Dürre betroffen. Die damit einhergehenden, mehrheitlich negativen Auswirkungen betreffen auch Waldökosysteme und die Forstwirtschaft. Die Vielzahl der Auswirkungen kombiniert mit der komplexen Charakteristik von Dürreereignissen erschwert eine Bewertung des Dürrierisikos als Kombination beider Aspekte.

Das Ziel dieser Masterarbeit ist es, verschiedene Informationen zu Auswirkungen von Dürre auf die Forstwirtschaft in Deutschland zu sammeln und diese im Rahmen einer statistischen Risikoanalyse mit verschiedenen Dürreindices in Verbindung zu setzen. Der Aufbau dieser Arbeit ist aufgrund der Verwendung von zwei unterschiedlichen Auswirkungsdatensätzen zweigeteilt:

Der erste Teil dieser Thesis analysiert das Dürrierisiko anhand von qualitativen Wirkungsberichten der EDII Datenbank und orientiert sich an den in Abschnitt 1.4.3 präsentierten Forschungsansätzen. Die vorangegangenen Studien haben vor allem die Sektoren Landwirtschaft, Energie und Industrie, öffentliche Wasserversorgung und Süßwasserökosysteme untersucht. Eine Studie, die systematisch den Zusammenhang zwischen EDII Wirkungsberichten im Forstsektor und Dürreindices in Deutschland analysiert, ist in dieser Form nicht vorhanden. Teilziele der ersten Untersuchung sind:

1. Der Zusammenhang zwischen Auswirkungsdaten und verschiedenen Dürreindices soll statistisch untersucht werden. Es sollen verschiedene Akkumulationsperioden der bekannten meteorologischen Dürreindices SPI und SPEI als auch Indices, die Bodenfeuchteanomalien beschreiben (SMI), miteinander verglichen werden. Generell soll die Hypothese geprüft werden, ob eine meteorologische Dürre Auswirkungen im Forstbereich vorausgeht.
2. Des Weiteren soll die Hypothese geprüft werden, ob längere Akkumulationsperioden der meteorologischen Indices sich besser eignen, die Auswirkungen im forstlichen Sektor zu beschreiben, da forstliche Systeme eher auf längerfristige Wasserdefizite reagieren. Außerdem wird vermutet, dass die Temperatur einen bedeutenden Einfluss auf Dürreauswirkungen im Forstsektor hat und aufgrund dessen der SPEI besser geeignet ist als der SPI, um die Auswirkungen zu modellieren.
3. Um den Einfluss der räumlichen Heterogenität zu beurteilen, werden die Analysen in 36 unterschiedlichen Verwaltungsebenen in Deutschland (NUTS-2-Regionen) durchgeführt. Es soll untersucht werden, ob sich verschiedene Indices in verschiedenen Regionen am besten eignen, um die Auftrittswahrscheinlichkeit von Auswirkungen vorherzusagen, oder ob ein Index regionsübergreifend die beste Modellperformance bewirkt.
4. Der zeitliche Versatz der Reaktion soll untersucht werden. Dazu werden die Indices mit den Auswirkungen des Folgejahrs statistisch in Verbindung gebracht. Die Hypothese lautet, dass die Zusammenhänge aufgrund der zeitlich versetzten Reaktion des Forstes auf Dürreereignisse im Folgejahr stärker sind.

Im zweiten Teil dieser Arbeit werden Kronenentlaubungsdaten der ICP Forest als Antwortvariable für die Waldgesundheit verwendet. Der Zusammenhang zwischen Kronenentlaubungsdaten und verschiedenen Dürreindices wurde in dieser Form auf Gesamtdeutscher Ebene noch nicht durchgeführt (siehe Abschnitt 1.4.4). Zusätzlich sollen Informationen über das Standalter, verschiedene standortspezifische Faktoren und die räumlich-zeitliche Heterogenität berücksichtigt werden. Die Teilabschnitte der zweiten Untersuchung sind:

5. Die Identifizierung von zeitlichen Trends der Kronenentlaubung für die vier Hauptbaumarten in Deutschland (*Fagus*, *Picea*, *Pinus* und *Quercus sp.*) sowie in den verschiedenen NUTS-2-Regionen. Aufgrund der unterschiedlichen baumspezifischen klimatisch-vegetativen Optima werden unterschiedliche Muster für die Baumarten erwartet.
6. Der Zusammenhang zwischen Kronenentlaubung und Dürreindices soll gemeinsam mit standortsspezifischen Faktoren in einem *linear mixed effect model* Ansatz untersucht werden. Dabei soll zum einen der Dürreindex mit dem besten Modellfit je Baumart identifiziert werden, zum anderen der Einfluss von Standortfaktoren (Standalter, nutzbare Feldkapazität nFK, Höhe) sowie die räumliche Heterogenität der Ergebnisse im Allgemeinen beurteilt werden. Die Unterschiede und Gemeinsamkeiten zwischen den vier Hauptbaumarten sollen herausgearbeitet werden.

Ein umfassenderes Verständnis der Auswirkungen im Forstsektor in Deutschland könnte in Zukunft dabei helfen, die Folgen von Dürre durch ein verbessertes Dürremanagement zu mindern.

3 Methoden

Das folgende Kapitel befasst sich mit dem Untersuchungsgebiet, der Datengrundlage und –Aufbereitung sowie den statistischen Methoden dieser Arbeit, welche angewandt wurden, um die Fragen und Hypothesen aus Abschnitt 2 zu beantworten.

3.1 Untersuchungsgebiet

3.1.1 Forstliche Flächen in Deutschland

Alle forstlichen Flächen in Deutschland (Laub-, Nadel- und Mischwälder sowie Wald- und Strauch Übergangsvegetation) sind in Abbildung 2 dargestellt. Die Abbildung basiert auf CORINE Land Cover Daten (CLC), wobei es sich um ein staatenübergreifendes Konzept für die Gewinnung von Informationen zur Landnutzung mittels Satellitenfernerkundung handelt (UBA, 2019a). Die Kartierung der CLC-Daten wurde im europäischen Maßstab (25 ha Mindestkartiereinheit) für den Zeitraum 1990 – 2018 durchgeführt. Die Daten werden vom Umweltbundesamt online angeboten (UBA, 2019b) und wurden mit der Software QGIS (QGIS Entwicklungsteam, 2019) visualisiert. In Deutschland sind laut Ergebnissen der Bundeswaldinventur von 2012 11,4 Mio. Hektar bewaldet, was einem Flächenanteil von 32% der Landfläche entspricht (BMLE, 2017). Der prozentuale Anteil der Waldfläche je Bundesland ist in Tabelle 1 angegeben.

Tabelle 1: Prozentualer Anteil der Waldfläche je Bundesland (2012) (BMLE, 2017)

Bundesland	%-Waldfläche	Bundesland	%-Waldfläche
Schleswig-Holstein	11%	Sachsen-Anhalt	26%
Mecklenburg-Vorpommern	24%	Sachsen	29%
Niedersachsen	25%	Thüringen	34%
Nordrhein-Westfalen	27%	Rheinland-Pfalz	42%
Hamburg & Bremen	12%	Saarland	40%
Berlin & Brandenburg	37%	Baden-Württemberg	38%
Hessen	42%	Bayern	37%




Abbildung 2: CORINE Landnutzungsklassen 3.1.1 (Laubwälder), 3.1.2 (Nadelwälder), 3.1.3 (Mischwälder) und 3.2.4 (Wald/Strauch Übergangsvegetation) in Deutschland für das Bezugsjahr 2018 (Auflösung 25 ha)

3.1.2 NUTS-Regionen

Die NUTS-Klassifikation (*frz.: Nomenclature des Unités territoriales statistiques*) ist ein hierarchisches System zur Untergliederung des EU Wirtschaftsraums in drei Stufen (NUTS-1 – NUTS-3) (Europäische Kommission, 2015). Sie dient unter anderem der Erfassung, Entwicklung und Harmonisierung regionalstatistischer Daten der EU, Erstellung soziökonomischer Analysen der Regionen sowie der Gestaltung der EU-Regionalpolitik (Europäische Kommission, 2019). Jeder NUTS-Region wird ein eindeutiger Code zugewiesen, dessen Länge von der jeweiligen NUTS-Ebene abhängt. In Deutschland entsprechen die 16 NUTS-1 Gebiete den Bundesländern und die 38 NUTS-2 Gebiete den Regierungsbezirken, ehemaligen Regierungsbezirken sowie neun Ländern, die auf dieser Ebene nicht

weiter untergliedert sind: Die drei Stadtstaaten Berlin (BE) , Bremen (HB) und Hamburg (HH) sowie die „Flächenländer“ Brandenburg (BB), Mecklenburg-Vorpommern (MV), Schleswig-Holstein (SH), Saarland (SL), Sachsen-Anhalt (ST) und Thüringen (TH) (Abbildung 3). Die NUTS-3-Ebene umfasst 402 Regionen und entspricht den Landkreisen und kreisfreien Städten (Europäische Kommission, 2015).

Die Auswertungen dieser Studie wurden auf NUTS-2-Ebene durchgeführt. Aufgrund der räumlichen und zeitlichen Unterschiede zwischen den grob aufgelösten Dürreauswirkungsdaten und den hochaufgelösten Dürreindizes musste ein Kompromiss gefunden werden, auf welcher räumlichen Ebene der Zusammenhang zwischen Dürreauswirkungsdaten und Dürreindizes untersucht werden sollte.



Abbildung 3: NUTS-1 und NUTS-2-Ebenen in Deutschland. (Dörrbecker, 2019).

3.2 Datengrundlage und Datenaufbereitung

Die Datenaufbereitung der Indices und Auswirkungsdaten sowie alle statistischen Analysen wurden mit dem Programm R, Version 3.5.1 (R Core Team, 2018) und der Benutzeroberfläche RStudio durchgeführt (RStudio Team, 2016).

3.2.1 Dürre Indices: SPI, SPEI und SMI

Wie bereits in Abschnitt 1.4.2 erläutert wurde, existiert eine Vielzahl an Dürreindices. Für diese Arbeit wurden zwei der geläufigsten meteorologischen Dürreindices, der SPI und der SPEI, sowie der Bodenfeuchteindex SMI, gewählt. Die Berechnung sowie die Vor- und Nachteile dieser Dürreindices wird im folgenden Abschnitt erläutert.

3.2.1.1 Meteorologische Indices SPI und SPEI

Zwei der bekanntesten meteorologischen Dürreindices sind der Standardisierte Niederschlagsindex (*Standardized Precipitation Index* (SPI)) nach McKee et al. (1993) sowie der Standardisierte Niederschlags-Verdunstungsindex (*Standardized Precipitation Evaporation Index* (SPEI)) nach Vicente-Serrano et al. (2010). Beide vergleichen den akkumulierten Niederschlag bzw. die klimatische Wasserbilanz in einer bestimmten Region während einer variablen Zeitspanne n (in Monaten) mit ihrem langjährigen Mittel (Vicente-Serrano et al., 2010; Zargar et al., 2011). Der SPI wird von der *World Meteorological Organization* (WMO) empfohlen und wird deshalb häufig zur Dürreidentifizierung in Europa verwendet (z.B. Stagge et al. (2015)). Der SPI wurde entwickelt, um die zeitliche Variabilität von Niederschlagsdefiziten gegenüber Bodenfeuchte, Abfluss, Reservoir-Speicher und Grundwasserstand abzubilden (Lloyd-Hughes und Saunders, 2002; Lloyd-Hughes, 2014). Für die Berechnung des SPI wird eine langjährige Niederschlagszeitreihe an eine Wahrscheinlichkeitsverteilung f (Gamma Verteilung) angepasst und anschließend in die Form einer Standardnormalverteilung transformiert. Für den gewählten Ort und Zeitabschnitt ist somit der Mittelwert $\mu = 0$ und die Standardabweichung $\sigma = 1$ (McKee et al., 1993; Mishra und Singh, 2010). Die Vorteile des SPI liegen in seiner Einfachheit: er ist nur vom Niederschlag abhängig, kann ganzjährig verwendet werden, die Topographie hat keinen Einfluss und die Zeitskala des Index kann variabel gewählt werden (Lloyd-Hughes und Saunders, 2002). Der SPI bietet sich demnach für eine Vielzahl von kurz- und langfristigen Anwendungen an. Da der SPI ein standardisierter Index ist, können Orte mit unterschiedlichen Niederschlagsregimes miteinander verglichen werden. Dies führt jedoch auch dazu, dass die Frequenz extremer Ereignisse an jedem Ort und zu jeder Zeitskala konsistent ist (Tabelle 2). Die Wahrscheinlichkeiten gehen aus der Normalverteilung hervor und somit ist das Auftreten von extremem SPI Werten per Definition festgelegt (Lloyd-Hughes und Saunders, 2002). Die Berechnung des SPI für kurze Zeiträume (1-3 Monate) in Regionen mit geringem Niederschlag kann in irreführenden stark positiven oder negativen SPIs resultieren (Lloyd-Hughes und Saunders, 2002; Mishra und Singh, 2010).

McKee et al. (1993) empfiehlt für die Standardisierung eine Zeitreihe von mindestens 30 Jahren. Die Dürreintensität wird üblicherweise durch definierte Grenzwerte kategorisiert (Tabelle 2).

Tabelle 2: Dürre Klassifikation für SPI und SPEI (McKee et al., 1993; Spinoni et al., 2016)

Wertebereich SPI/SPEI	Klassifizierung	Wahrscheinlichkeit [%]
$-1,0 < \text{SPI/SPEI} < 1,0$	Normale Klimaschwankungen	68,2
$-1,5 \leq \text{SPI/SPEI} < -1$	Moderate Dürre	9,2
$-2 \leq \text{SPI/SPEI} < -1,5$	Schwere Dürre	4,4
$\text{SPI/SPEI} < -2$	Extreme Dürre	2,3

Eine Weiterentwicklung des SPI stellt der eingangs erwähnte SPEI dar (nach Vicente-Serrano et al. (2010)). Statt des Niederschlags berechnet der SPEI die klimatische Wasserbilanz (Niederschlag – potentielle Evaporation). Der SPEI weist dieselben Vorteile wie der SPI auf (geringer Datenbedarf, einfache Interpretation, zeitliche Flexibilität), vermeidet jedoch die zuvor erwähnten Probleme des SPI mit geringen Niederschlagsmengen. Dadurch hat sich der SPEI zu einer häufig genutzten Alternative entwickelt (z.B. Beguería et al. (2010), Blauhut et al. (2015)). Durch die Berücksichtigung von Temperatur bietet dieser Index in wärmeren Klimaten möglicherweise eine bessere Quantifizierung von Dürre an (Beguería et al., 2014).

Die in dieser Studie verwendeten Dürreindices SPI und SPEI wurden von Jost Hellwig, Doktorand der Hydrologie an der Universität Freiburg, bereitgestellt. Die für die Berechnungen der Indices verwendeten Klimadaten des Niederschlags und der Lufttemperatur mit einer Auflösung von 0,25 Grad stammen aus der E-OBS Datenbank (Version 19.0e) (C3S, 2019). Die E-OBS Rasterdaten beinhalten in täglicher Auflösung unter anderem Niederschlag, Minimal-, Maximal- sowie Tagesmittel der Lufttemperatur. Eine Beschreibung der Datenbank ist in Cornes et al. (2018) gegeben. Tägliche Niederschlagssummen wurden auf Monatswerte aufsummiert. Für alle Regionen der drei NUTS-Ebenen in Deutschland wurden die Werte gemittelt und dienten als Grundlage für die Berechnung der Dürreindices.

Für jeden Monat, Akkumulationszeitraum der Indices und jede NUTS-Region wurde eine Verteilung an den Niederschlag angepasst, auf Standardnormalverteilung transformiert ($\mu = 0$, $\sigma = 1$) und mit Niederschlagsdaten von 1950 bis 2018 standardisiert. Für den SPI wurde die Gamma-Verteilung gewählt, für den SPEI aufgrund der besseren Anpassung die logistische Verteilung. Die Berechnung der Indices erfolgte mittels des Paketes *SCI* (Gudmundsson und Stagge, 2016) in R. Die Evapotranspiration nach Hargreaves wurde mit dem Paket *SPEI* (Beguería et al., 2017) berechnet. Einer der großen Vorteile von SPI und SPEI ist ihre zeitliche Flexibilität. In Punkt 2 der Fragestellung wurde die Hypothese aufgestellt, dass forstliche Systeme auf längerfristige Wasserdefizite reagieren. Aus diesem Grund wurden für beide Indices vier unterschiedliche Akkumulationsperioden gewählt (3, 6, 12 und 24 Monate). Der SPEI-3 für den Monat August ist z.B. der standardisierte Niederschlag von Juni – August, der SPEI-6 von

September dementsprechend der standardisierte Niederschlag von April – September. Das bedeutet, je größer die Akkumulationszeiten sind, desto stärker ist die Korrelation zwischen den Werten eines Monats mit den Werten des vorangegangenen Monats, da sich die Zeitspannen zu großen Teilen überlagern.

Da die Auswirkungsdaten auf Jahresbasis vorliegen (siehe Abschnitt 3.2.2.1), wurde für jedes Jahr und jede Akkumulationsperiode ein repräsentativer Index gewählt. Aufgrund der Tatsache, dass in dieser Studie Dürreauswirkungen im Forstsektor untersucht werden sollen, sind die Dürreindices während der Vegetationsperiode von Interesse. Aufgrund dessen wurden für die SPI/SPEI-3 der Wert von August (Sommermonate Jun – Aug), die SPI/SPEI-6 der Wert für September (Sommerhalbjahr April – Sept) und die SPI/SPEI-12/24 der Wert für Oktober gewählt. Für die Letzteren wurde der Oktober gewählt, da in den Monaten November und Dezember keine Vegetationsphase ist. Wenn in der Folge die Indices genannt werden, beziehen sich die Aussagen immer auf die genannten Zeiträume. Aufgrund der begrenzten Verfügbarkeit der Auswirkungsdaten wurde der Untersuchungszeitraum auf die Zeitspanne von 1975 – 2018 begrenzt.

3.2.1.2 Bodenfeuchteindex SMI

Seit 2014 existiert mit der Veröffentlichung des Deutschen Dürremonitors (GDM) am Helmholtz-Zentrum für Umweltforschung (UFZ) ein hochauflösendes, regionales Monitoring mit Informationen zu landwirtschaftlicher Dürre (Marx et al., 2016; Zink et al., 2016). Im Wesentlichen besteht das operationelle System aus vier Schritten:

1. Die Datenbasis bilden tägliche meteorologische Daten des Climate Data Center (CDC) des DWD. Diese werden einer Qualitätsprüfung unterzogen und auf ein 4x4 km² Gitter interpoliert. Die potentielle Evaporation wird berechnet. Eine flächendeckende Verfügbarkeit der Daten existiert mit vier Tagen Verzögerung, weshalb der GDM ein „near-realtime“ Produkt bereitstellt.
2. Die meteorologischen Daten treiben das mesoskalische hydrologische Modell mHM an (Samaniego et al., 2013). Das mHM ist ein prozessbasiertes Wasserhaushaltsmodell, bei dem Schneeakkumulation und Schmelze, Interzeption, Interflow und Grundwasserneubildung berücksichtigt werden. Für jede Zelle werden Direktabfluss, Basisabfluss sowie langsamer und schneller Interflow berechnet. Ergebnisse sind die Bodenfeuchten in drei Bodenschichten (5 cm, 20 cm sowie variabel in Abhängigkeit der Bodenart, im Schnitt 1,80 m in Deutschland). Eine umfangreichere Evaluation des Modells ist in Samaniego et al. (2013) gegeben.
3. Im dritten Schritt werden die modellierten täglichen Bodenfeuchtedaten in einen Bodenfeuchteindex (SMI) umgerechnet. Die täglichen Bodenfeuchtedaten werden als gleitendes Mittel der Bodenfeuchtebedingungen der vergangenen 30 Tage modelliert. Für jede Gitterzelle und jeden Tag wird eine kumulative Verteilungsfunktion für die Bodenfeuchte bestimmt. Als Referenzzeitraum für die Berechnung der Verteilungsfunktion dient die 60 Jahre

lange Zeitreihe meteorologischer Daten von 1954 – 2013. Die Berechnung des Soil Moisture Index (SMI) repräsentiert die Perzentile der simulierten monatlichen Bodenfeuchte und nimmt somit Werte zwischen 0 und 1 an. Die Standardisierung des Index orientiert sich an anderen, normalisierten Indices (e.g. SPI, SPEI). Hohe Indexwerte (>0.5) stehen für statistisch feuchte Bedingungen, kleine Werte repräsentieren statistisch trockene Bedingungen.

4. Die berechneten SMI Werte werden in fünf Klassen eingeteilt, wobei vier Klassen verschieden starke Dürrestufen beschreiben und eine fünfte als Vorwarnstufe existiert: „ungewöhnlich trocken“ ($0.3 \leq \text{SMI} < 0.2$), „moderate Dürre“ ($0.2 \leq \text{SMI} < 0.1$), „schwere Dürre“ ($0.1 \leq \text{SMI} < 0.05$), „extreme Dürre“ ($0.05 \leq \text{SMI} < 0.02$) und „außergewöhnliche Dürre“ ($\text{SMI} \leq 0.02$). Die letzte Stufe bildet ein Wiederkehrintervall von 50 Jahren ab.

Der SMI ist ebenso wie der SPI oder SPEI ein relativer Index, der die Abweichung der Bodenfeuchte vom langjährigen Zustand im jeweiligen Monat angibt, jedoch keine Aussage über die absolute Bodenfeuchte trifft. Eine detailliertere Beschreibung der Modellkette ist in Marx et al. (2016) und Zink et al. (2016) gegeben. Die Berechnung des Bodenfeuchteindex SMI sowie die Unsicherheiten in der Methodik sind in Samaniego et al. (2013) beschrieben. Tagesaktuelle Vektorgrafiken und historische SMI-Daten können der Webseite des Helmholtz Zentrums für Umweltforschung entnommen werden (UFZ, 2019).

Für diese Studie wurde der SMI in zwei unterschiedlichen Bodentiefen verwendet: der SMI 25, der die Bodenfeuchte im Oberboden (bis 25 cm) beschreibt, und der SMI 180, der die mittlere Bodentiefe in Deutschland beschreibt (bis 180 cm). Der SMI des UFZ liegt ab 1951 in monatlicher Auflösung in einem Raster von $4 \times 4 \text{ km}^2$ vor. Das entspricht 39375 Rasterzellen pro Zeitschritt. Das Raster des Bodenfeuchteindex wurde mit den NUTS-2-Regionen verschnitten. Für jede NUTS-2-Region wurden allen Rasterzellen, deren Mittelpunkt innerhalb der Grenzen der jeweiligen NUTS-2-Region lag, zusammengefasst: Für jede NUTS-2-Region wurde das 5% Perzentil des SMI für jedes Jahr berechnet. Das 5% Perzentil wurde verwendet, da davon ausgegangen wird, dass trockene Extreme entscheidend für Dürreauswirkungen sind. Das 5%-Perzentil wurde dem Minimum vorgezogen, da es robuster gegenüber eventuellen Modellierungsfehlern ist. Eine Mittelung der SMI Werte über mehrere Monate ist nicht sinnvoll, da monatliche Bodenfeuchteindices bereits das längerfristige Wasserangebot widerspiegeln.

3.2.2 Auswirkungsdaten von Dürre

3.2.2.1 *European Drought Impact report Inventory (EDII)*

Systematisch erhobene, quantitative Daten über Auswirkungen von Dürre im Umwelt- und sozio-ökonomischen Bereich sind häufig ein fehlender Baustein im Bereich des Dürremanagements (Stahl et al., 2016). Der Fokus liegt meist auf den physikalischen (meteorologischen und hydrologischen) Aspekten von Dürre. Hayes et al. (2011) bemängelt das Fehlen eines grundlegenden Verständnisses

über die Bedeutung von Dürreauswirkungsdaten und ein mangelndes Wissen darüber, welche Daten gesammelt werden sollen. Das Monitoring von Auswirkungsdaten gestaltet sich häufig als schwierig, da diese in ihrer Intensität und ihrem zeitlichen Auftreten während (oder nach) dem Dürreereignis variieren. Weiterhin werden Auswirkungsdaten häufig von verschiedenen Organisationen (z.B. Landwirtschaft, Fischerei, Wasserkraft, etc.) dezentral gesammelt und verwaltet (Stahl et al., 2016). Eine grenz- und sektorenübergreifende Bewertung von Dürreauswirkungen ist besonders in der EU, welche sich durch verschiedene geoklimatische Regionen kennzeichnet, von Bedeutung (Stahl et al., 2016). Aus diesem Grund wurde im Jahr 2012 im Zuge des EU FP-7 Project DROUGHT-R&SPI (EDC, 2015) die *European Drought Impact report Inventory* (EDII) eingeführt, eine textbasierte Datenbank mit dem Zweck, qualitative und sektorenübergreifende Dürreauswirkungsdaten für Europa zu sammeln. Per Definition werden Dürreauswirkungen (*drought impacts*) in der EDII Datenbank als negative Effekte im Umwelt-, Wirtschafts- und sozialen Bereich unter Dürrebedingungen bezeichnet (Bachmair et al., 2015). Die Berichte stammen aus einer Vielzahl von Quellen: Berichte staatlicher oder nicht-staatlichen Organisationen, Bücher, sowie Artikel aus Zeitungen, Fachzeitschriften und digitale Medien (Bachmair et al., 2015; Stahl et al., 2016) und beschreiben sowohl direkte als auch indirekte Folgen von Dürre. Die Datenbank wächst kontinuierlich und beinhaltet bereits über 7700 Berichte aus 38 Ländern (Stand Mai 2019). Damit ein Bericht in die Datenbank aufgenommen wird, muss gewährleistet sein, dass die berichtete Auswirkung eindeutig eine Folge von Dürre ist und der Bericht einer verlässlichen Quelle entstammt (Zitation vorhanden). Alle berichteten Auswirkungen werden möglichst genau in ihrem räumlichen und zeitlichen Auftreten referenziert. Als räumliche Ebene muss mindestens das Land, wenn möglich auch die entsprechende Klassifikation (NUTS) gegeben sein. Als zeitliche Referenz sollte mindestens das Auftrittsjahr, im Idealfall die Saison oder der jeweilige Monat angegeben sein. Alle Berichte werden einer von 15 vordefinierten Kategorien (Sektoren) zugeteilt (z.B. Landwirtschaft, Forstwirtschaft, Energie und Industrie oder öffentliche Wasserversorgung), die wiederum in verschiedene Unterkategorien eingeteilt sind (insgesamt 105). Zusätzlich wird jeder Eintrag mit einer kurzen Beschreibung versehen (Stagge et al., 2015). Eine ausführliche Dokumentation sowie Zugang zur Datenbank ist auf der Website des *European Drought Centre* gegeben (EDC, 2013).

Alle Einträge zu Auswirkungen in Forstbereich (*impact category 2*) für Deutschland wurden aus der EDII Datenbank extrahiert (Stand 16.05.2019). Nach einer ersten Sichtung der zeitlichen Datenverfügbarkeit wurde der Untersuchungszeitraum auf Einträge ab 1975 beschränkt. Einträge, die mehrere NUTS Regionen oder mehrere Subkategorien betreffen, wurden in mehrfache Auswirkungen aufgeteilt: eine Auswirkung bezieht sich auf eine NUTS Region und eine Subkategorie (Methodik u.a. in Bachmair et al. (2015) angewandt). Insgesamt waren 102 Einträge vorhanden, welche auf NUTS-2-Ebene differenziert waren sowie 178 Einträge, welche nur auf NUTS-1-Ebene skaliert waren. Eine Übersicht aller Einträge auf NUTS-1-Ebene (Bundesländer) ist in Abbildung 4 gegeben. Aufgrund der Tatsache, dass Dürren per Definition seltene Ereignisse sind, ist die Anzahl der Jahre ohne Dürreauswirkung deutlich größer als die Anzahl der Jahre mit Dürreauswirkung (Blauhut et al., 2015).

Um räumliche und zeitliche Auftrittscharakteristika von Dürreauswirkungen auf NUTS-2-Ebene zu untersuchen, werden die vorhandenen, unbearbeiteten Auswirkungsdaten als nicht ausreichend angesehen. Eine Skalierung der EDII Daten auf eine höhere, gemeinsame NUTS Ebene wurde bereits in vergangenen Arbeiten durchgeführt. Blauhut et al. (2015) transformierte die Daten auf eine eigens geschaffene NUTS Combo Skala. In dieser Arbeit wurden alle EDII Einträge, welche nur Angaben auf NUTS-1-Ebene differenziert waren, auf NUTS-2-Ebene skaliert. Dabei wurden die Berichte ohne Flächengewichtung übertragen: Für jeden Eintrag auf NUTS-1-Ebene bekommen alle NUTS-2-Regionen innerhalb dieser NUTS-1 Region einen Eintrag zugeordnet. Durch diese Skalierung kann der Eindruck entstehen, dass die Auswirkungen größere Bereiche abdecken, als sie es eigentlich getan haben (Blauhut et al., 2015). Nach der Skalierung waren insgesamt 773 Einträge für alle NUTS-2-Regionen in Deutschland ab 1975 vorhanden. Zeitlich konnten die Daten nur auf Jahresebene differenziert werden, da zu wenige der Einträge im Forstbereich spezifischere Angaben zum Auftrittszeitpunkt hatten. Einträge mit monatlicher oder saisonaler Referenz zum Auftrittszeitpunkt wurden somit auf das Auftrittsjahr generalisiert (Blauhut et al., 2015). Eine Beschreibung der Unterkategorien sowie die prozentuale Verteilung der Einträge in den jeweiligen Subkategorien zeigt Abbildung 5.




Abbildung 4: Anzahl der EDII Einträge in der Kategorie Forst je Bundesland ab 1975




Abbildung 5: Prozentuale Anzahl der Unterkategorien der EDII Einträge im Forstsektor in Deutschland ab 1975. **2.1:** Vermindertes Baumwachstum/Vitalität; **2.2:** Abnahme jährlicher Nichtholzprodukte (Kork etc.); **2.3:** Erhöhtes Auftreten von Wasserstressindikatoren und Schadenssymptomen (Kronenentlaubung etc.); **2.4:** Zunahme von Baumkrankheiten oder Schädlingen; **2.5:** Zunehmendes Baumsterben; **2.6:** Zunehmendes Absterben von Baumsetzlingen (in bewirtschafteten Gebieten); **2.8:** andere Auswirkungen; **2.9:** Zunahme von wirtschaftlichen Verlusten/Kosten

3.2.2.2 ICP Forest data (Level I)

Die ‘*International Co-operative Programme on Assessment und Monitoring of Air pollution Effects on Forests*’ (ICP Forest) wurde 1985 von der ‘*Economic Commission for Europe of the United Nations*’ (UNECE) nach der ‘*Convention on Long-Range Transboundary Air Pollution*’ (CLRTAP) ins Leben gerufen (Seidling et al., 2017; Eickenscheidt et al., 2019). Das Hauptziel des Programms ist die Überwachung der Waldgesundheit in Europa. Hierfür wird die Waldgesundheit in zwei Stufen unterschiedlicher Intensität überwacht:

- Das Level-I Monitoring bietet großflächig einen regelmäßigen Überblick über räumliche und zeitliche Variationen einer Vielzahl an Eigenschaften in Bezug auf die Waldgesundheit an (Seidling et al., 2017). Ins Leben gerufen wurde das Monitoring, um die Rolle der Luftverschmutzung bei Baumsterben zu beurteilen (Michel und Seidling, 2016). Sie wird in Europa mindestens in einem 16 x 16 km Netz überall dort, wo Wald auftritt, durchgeführt (Ferretti et al., 2017; Eickenscheidt et al., 2019).
- Das Level-II Monitoring sind intensive Untersuchungen an Ständen (*plots*) in wichtigen Waldökosystemen. Hier sollen tiefgreifende Untersuchungen von natürlichen und anthropogenen Stressoren der Waldgesundheit vorgenommen werden (Seidling et al., 2017).

In dieser Studie werden ausschließlich Level-I Daten verwendet. Der Hauptparameter bei der Waldzustandsbewertung auf Level-I Ebene ist die Kronenentlaubung, welche den Nadel- oder Blattverlust eines Baumes im Vergleich zu einem lokalen oder absoluten Referenzbaum beschreibt. Sie gilt als repräsentativ für die allgemeine Baumgesundheit und könnte somit ein Frühwarnsignal für die Verschlechterung der Waldgesundheit darstellen (Michel und Seidling, 2016). Die Kronenentlaubung wird von 0% (keine Entlaubung) bis 100% (toter Baum) in 5%-Schritten aufgenommen. Die Datenaufnahme erfolgt nach dem aktuellen Europäischen Protokoll zur Erhebung der Kronenentlaubung

(Eichhorn et al., 2017). Die Abschätzung der Kronenentlaubung findet visuell mittels Ferngläsern statt. Aufgrund der Subjektivität bei der Aufnahme dieser Daten soll ein Qualitätssicherungsprogramm die Konsistenz und Reproduzierbarkeit der Daten gewähren (Eichhorn et al., 2017; Eickenscheidt et al., 2019). Dieses besteht unter anderem aus Fortbildungslehrgängen, welche in den Sommermonaten vor der Datenaufnahme im Feld stattfinden. Diese regelmäßigen Fortbildungen minimieren die Subjektivität in der Datenaufnahme der Kronenentlaubungsdaten (Eickenscheidt und Wellbrock, 2014). Das gesamte, aktuelle ICP Forest Manual ist auf der Website des ICP Forest verfügbar (ICP Forest, 2016).

In Deutschland findet die Beurteilung der Kronenentlaubung jährlich seit 1990 statt. Einzelne Bundesländer haben seitdem eine Verdichtung des 16 x 16 km Rasternetzes vorgenommen. Dies hat zur Folge, dass die Rasternetze und somit die Zeitreihen der Kronenentlaubung unregelmäßig sind, was eine Herausforderung für räumlich – zeitliche statistische Analysen darstellt (Eickenscheidt et al., 2019). Einzelne Stände bestehen meist aus 24 Bäumen, mit sechs Bäumen in jede Himmelsrichtung im Abstand von 25 m zum Zentrum. Eine ausführliche Beschreibung des Standaufbaus ist in Eichhorn et al. (2017) gegeben.

Die Level-I Daten werden durch das Thünen-Institut bereitgestellt. Abbildung 6 gibt einen schematischen Überblick über die Verteilung der Level-I Stände in Deutschland (insgesamt 613 verschiedene seit 1990), an denen die Kronenentlaubung jährlich erhoben wird. Die vier Hauptbaumarten in Deutschland, auf deren Untersuchung sich diese Studie beschränkt, machen insgesamt ca. 76% aller untersuchten Bäume seit 1990 aus (26,3% Gemeine Fichte (*Picea abies*), 23,0% Waldkiefer (*Pinus sylvestris*), 17,4%, Rotbuche (*Fagus sylvatica*) und 9,4% Eichen (*Quercus sp.*)).




Abbildung 6: ICP Forest Level-I Stände in Deutschland (613 insgesamt)

Die Zeitreihen der Kronenentlaubung der einzelnen Bäume in den jeweiligen Ständen wurden mit standortspezifischen Informationen (Höhe über Meeresspiegel, nFK in drei verschiedenen Bodentiefen, Hangneigung, geografische Länge und Breite, durchschnittliches Standalter) zusammengeführt. Jedem Stand wurde die zugehörige NUTS-2-Region, in der er sich befindet, zugeordnet. Altersangaben waren nur als durchschnittliches Standalter der dominierenden Baumart und nicht auf individueller Baumebene vorhanden. Das Standalter wird geschätzt und in Altersklassen mit Intervallen von 20 Jahren eingeteilt (von <20 – >120 Jahre) (Eichhorn et al., 2017). Das Standalter muss mindestens alle fünf Jahre oder aber wenn grundlegende Veränderungen in der Altersstruktur des Standes auftreten, bestimmt werden. Um einen numerischen Wert für das Standalter eines jeden Jahres zu erhalten, wurde jeweils die Mitte der jeweiligen Altersklasse gewählt (z.B.: 21 – 40 Jahre = 30 Jahre). Für Jahre ohne Angaben des Standalters wurde jeweils das Alter der letzten Schätzung angenommen. Stände mit der Altersangabe „unregelmäßiger Stand“ wurde keine Altersangabe zugeordnet. Die Altersangaben wurden auf verdächtig große Sprünge zwischen aufeinanderfolgenden Jahren untersucht. In Absprache mit der Datenbankbeauftragten des Thuenen-Instituts (P. Duehnelt) wurden einige Altersangaben korrigiert, die offensichtlich systematische, grobe Fehler aufwiesen. Eine Übersicht der durchschnittlichen Anzahl an untersuchten Bäumen je NUTS-2-Region sowie die gesamte Anzahl je Baumart ist in Tabelle Anhang 3 gegeben.

3.3 Statistische Analysen

Die folgenden Abschnitte erläutern die in dieser Arbeit angewandten statistischen Methoden. Die EDII Daten wurden als binäre Antwortvariable mittels logistischer Regression modelliert. Für jeden Index und jede NUTS-2-Region wurden separate Modelle angepasst, um die Leistungsfähigkeit der Dürreindices untereinander zu vergleichen und räumliche Unterschiede hervorzuheben.

Die ICP Forest Kronenentlaubungsdaten wurden nach den vier Hauptbaumarten *Fagus*, *Picea*, *Pinus* und *Quercus sp.* getrennt untersucht. Mittels *linear mixed effect models* sollte der Einfluss der Dürreindices sowie verschiedener standortspezifischer Prädiktoren auf die Kronenentlaubung bewertet und verglichen werden.

3.3.1 Vorausgehende Untersuchungen von Indices und Auswirkungsdaten (EDII)

Das Ziel des ersten Teils dieser Arbeit ist es, den funktionellen Zusammenhang zwischen Dürreauswirkungsdaten der EDII Datenbank und den verschiedenen Dürreindices zu untersuchen. Weiterhin sollen Unterschiede zwischen den jeweiligen Indices sowie räumliche und zeitliche Muster untersucht werden. Bevor ein Modell erstellt wurde, um diesen Zusammenhang zu analysieren, wurden einige Voruntersuchungen der Dürreindices und EDII Auswirkungsdaten vorgenommen.

Um die Indices grafisch auf einen Trend hin zu untersuchen, wurden die Zeitreihen der Indices der jeweiligen NUTS-2-Regionen als Spaghetti Abbildungen mit linearer Trendlinie abgebildet. Die Varianz der Indices sollte untereinander verglichen werden. Für einen ersten, grafischen Vergleich wurden Boxplots der Indices erstellt. Die Ergebnisse eines Shapiro-Wilk-Tests auf Normalverteilung und eines Levene-Test auf Varianzhomogenität innerhalb der Gruppen ergab, dass die Daten weder normalverteilt noch varianzhomogen sind. Beides sind Bedingungen für die Anwendung einer Varianzanalyse mittels ANOVA (Dormann, 2013). Deshalb wurde als Alternative ein Zweistichproben-t-Test (*pairwise-t-test*) angewandt, welcher keine Annahme der Normalverteilung sowie gleichen Varianzen der Gruppen benötigt (*p*-Werte nach Benjamini-Hochberg Methode justiert). Um die Abhängigkeit der Dürreindices untereinander sowie auf zeitlichen Trend hin zu untersuchen, wurde eine Korrelationsmatrix mittels des R-Pakets *corrplot* (Wei und Simko, 2017) visualisiert.

Um einen ersten Überblick über die räumliche-zeitliche Variation des Auftretens von Dürreauswirkungen in Deutschland zu bekommen, wurde das Auftreten von Auswirkungen (Ja/Nein) für jede NUTS-2-Region und jedes Jahr dargestellt. Des Weiteren wurde der prozentuale Anteil von ‚Auswirkung/keine Auswirkung‘ für jeden Index über den gesamten Wertebereich dargestellt. Dies kann einen ersten Eindruck vermitteln, welcher Index sich möglicherweise am besten eignet, um den funktionellen Zusammenhang zu beschreiben. Eine Annahme in Punkt 1 der Fragestellung ist, dass meteorologische Dürren den Dürreauswirkungen im Forst vorausgehen. Somit würden niedrige Werte von SPI, SPEI und SMI mit einer größeren Wahrscheinlichkeit für das Auftreten von

Dürreauswirkungen verbunden sein. Erwartungsgemäß wäre der Anteil ‚Auswirkung berichtet‘ umso größer, je kleiner der jeweilige Index wird. Einige Abbildungen wurden mithilfe des „*Worked example 12.2: Likelihood of impact occurrence*“ von Gauster und Stagge (2019) erstellt.

3.3.2 Logistische Regression

Um den funktionellen Zusammenhang zwischen Dürreindices und Dürreauswirkungen zu untersuchen, wurden die EDII Berichte zu einem binären Datensatz (Auswirkung berichtet: Ja/Nein) auf jährlicher Basis für jede NUTS-2-Region transformiert. Mittels logistischer Regression sollte der Zusammenhang zwischen den Dürreindices und der binären Antwortvariablen untersucht werden. Dürreauswirkungen wurden bereits in früheren Arbeiten mittels logistischer Regression modelliert (Gudmundsson et al., 2014; Stagge et al., 2015; Blauhut et al., 2015; Blauhut et al., 2016; Bachmair et al., 2017). Die logistische Regression schätzt die Auftrittswahrscheinlichkeit einer Dürreauswirkung (LIO: *likelihood of drought impact occurrence*) in Abhängigkeit der Dürreindices (*Index*) (Formel 1):

$$\log\left(\frac{LIO}{1 - LIO}\right) = \alpha + \beta * Index \quad (1)$$

Die linke Seite der Gleichung stellt die logit-Transformation dar, die rechte Seite die Modellparameter α und β , welche mittels Standard Regressionsverfahren (GLMs) geschätzt werden (Zuur et al., 2009). Die (logit-transformierte) Auftrittswahrscheinlichkeit (LIO) wird also als lineare Funktion des Prädiktors (*Index*) modelliert. Mit diesem logistischem Modell kann das Auftreten von Dürreereignissen zwar nicht mit ‚Auswirkung‘ und ‚keine Auswirkung‘ vorhergesagt werden, jedoch werden Schätzer im Bereich von 0 (0% Auftrittswahrscheinlichkeit) bis 1 (100% Austrittswahrscheinlichkeit) angegeben (Blauhut et al., 2015). Die Daten müssen logit-transformiert werden, da eine binäre Antwortvariable mittels likelihood statistisch problematisch zu modellieren ist: die Auswirkungen sind auf Werte zwischen 0 – 1 beschränkt, die Prädiktoren jedoch meist kontinuierlich (von $-\infty$ bis $+\infty$). Die logistische Regression transformiert die Wahrscheinlichkeiten (Formel 1) (Stagge et al., 2015).

Für jeden der zehn Dürreindices wurde in jeder NUTS-2-Region ein logistisches Regressionsmodell angepasst. Das Ziel war es, das beste logistische Regressionsmodell für jede NUTS-2-Region zu finden. Für die weiteren Analysen wurden nur die Modelle mit signifikantem Index ($p < 0,05$) beibehalten (Blauhut et al., 2015). Die Modellgüte („*goodness of fit*“) wurde über McFaddens *pseudo-R²* bestimmt (McFadden, 1974), welcher ein Gütemaß ähnlich dem traditionellen R^2 ist. Der traditionelle R^2 kann nicht für die logistische Regression berechnet werden, da R^2 nicht die Varianz minimiert, wie bei der „*ordinary least squares*“ Methode (OLS). *Pseudo-R²* imitiert die Eigenschaften von OLS R^2 (Stagge et al., 2015). McFaddens *pseudo-R²* wird in Menard (2000) für die logistische Regression empfohlen und wurde ebenfalls von Stagge et al. (2015) verwendet. Die Berechnung von Mcfaddens *pseudo-R²* ist in Formel 2 angegeben, in der $\ln$ der natürliche Logarithmus, L_M die geschätzte likelihood des gesamten Modells mit (allen) Prädiktoren und L_0 die likelihood eines Null Modells ohne Prädiktoren (nur *intercept*) ist.

$$R_{McF}^2 = 1 - \frac{\ln(L_M)}{\ln(L_0)} \quad (2)$$

Die Likelihood binärer Daten liegt für jede Beobachtung zwischen 0 – 1, also ist die log likelihood negativ. Wenn das Modell wenig Aussagekraft hat, dann ist der Quotient der obigen Formel Nahe 1 und somit *pseudo-R²* nahe 0. Werte von McFaddens *pseudo-R²* für logistische Regression sind oft kleiner als traditionelle *R²* Werte und werden bereits zwischen 20 – 40% als befriedigend angesehen (McFadden, 1974). Die modellierten LIO-Kurven wurden für jede NUTS-2-Region für den Index mit der jeweils besten Modellgüte dargestellt (Gauster und Stagge, 2019).

Des Weiteren sollte überprüft werden, ob sich die Modellgüte verbessert, wenn die Dürreindices mit den Auswirkungen des Folgejahres in Bezug gesetzt werden. Aufgrund dessen wurde ebenfalls für jeden Index in allen NUTS-2-Regionen eine logistische Regression mit einem Zeitversatz der Auswirkungen von einem Jahr gerechnet.

3.3.3 ROC-Analyse (Receiver Operating Characteristics)

Ein weiteres Qualitätsmaß für logistische Regressionsmodelle ist die ROC-Analyse (*Receiver Operating Characteristics*) (Mason und Graham, 2002). Die ROC-Analyse erlaubt die Leistungsfähigkeit von Dürreindices als Prädiktor für das Auftreten von Dürreauswirkungen untereinander zu vergleichen. Dieses grafische Analyseverfahren wurde ausgiebig im Bereich psychologischer und medizinischer Tests angewendet (Mason und Graham, 2002), findet jedoch vermehrt auch in naturwissenschaftlichen Studien Verwendung (Gudmundsson et al., 2014; Blauhut et al., 2015; Stagge et al., 2015; Blauhut et al., 2016). Die ROC-Analyse beschreibt die Modellfähigkeit, das Auftreten bzw. Nicht-Auftreten von Auswirkungen korrekt vorherzusagen. In diesem Verfahren sind die Vorhersagen binär definiert und in die Klassen „Warnung“ und „keine Warnung“ aufgeteilt. Die Klassen beschreiben also, ob eine Auswirkung erwartet wird oder nicht. Für logistische Regressionsmodelle variiert die Wahrscheinlichkeit, ab der eine Warnung ausgegeben wird, entlang einer Reihe von Grenzwerten (Mason und Graham, 2002). Der Grenzwert eines Index beschreibt den Punkt, an dem zwischen 0 („keine Warnung“) und 1 („Warnung“) unterschieden wird. Jeder Index-Wert wird einmal als Grenzwert verwendet und der Zusammenhang zwischen Vorhersage (Abfolge „Warnung“/„keine Warnung“) und Beobachtung (Abfolge Auftreten/kein Auftreten) untersucht. Die Übereinstimmung wird durch einen zwei-Komponenten Vektor beschrieben: der Trefferrate (*hit-rate*) und der „falscher-Alarm“ Rate. Die Trefferrate beschreibt den Anteil korrekt vorhergesagter Dürreauswirkungen (Sensitivität), die „falscher-Alarm“ Rate den Anteil falsch positiver Warnungen (Warnung ausgegeben, obwohl kein Ereignis stattfand (1 – Spezifität)). Diese beiden Werte geben eine 2-D Koordinate im ROC Raum und definieren gemeinsam die ROC-Kurve (Mason und Graham, 2002) (Abbildung 7). Als Gütemaß für die Leistungsfähigkeit des Modells dient die Fläche unter der ROC-Kurve bzw. AUC (*Area Under Curve*). Ein Verlauf der ROC-Kurve auf der Diagonalen kommt einer zufälligen Vorhersage gleich (AUC = 0.5). Ein AUC > 0,7 entspricht einer guten Modellleistung; ein AUC > 0,9 einer exzellente

Modellleistung und ein $AUC = 1,0$ würde ein perfektes Modell darstellen (Blauhut et al., 2016). Der ideale Schwellenwert ist Schnittpunkt der ROC-Kurve mit dem Lot der Hauptdiagonalen, bei dem das Lot den größten Abstand aufweist. Er kann über die Maximierung des Youden-Indexes ermittelt werden (Formel 3).

$$\text{Youden Index} = \text{Sensitivität} + \text{Spezifität} - 1 \quad (3)$$




Abbildung 7: Beispiel für eine ROC-Kurve. Bei einem Schwellenwert von 18,5 wird der maximale Abstand zur Diagonalen erreicht. Für diesen Schwellenwert würden eine Sensitivität von 0,94 erreicht werden, d.h., dass 94% aller Auswirkungen korrekt vorhergesagt werden. Zugleich werden 24% der Ereignisse zu Unrecht als solche klassifiziert ($1 - \text{Spezifität}$). Entnommen aus Moosbrugger und Kelava .(2012)

In R wurden die ROC-Diagramme mit dem Paket *pROC* erstellt (Robin et al., 2011), als Eingangsdaten dienten die skalierten, binären EDII Datensätze für Dürreauswirkungen auf NUTS-2-Ebene.

3.3.4 Dürrierisikokarten für Deutschland

Auf Basis der logistischen Regressionsmodelle lassen sich Risikokarten für den Forst Deutschland für verschiedene Gefahrenstufen von Dürre erstellen. Diese Dürrierisikokarten sollen idealerweise die Unterschiede zwischen NUTS-2-Regionen aufgrund unterschiedlicher Vulnerabilitäten und Ausgesetzttheit gegenüber Dürreereignissen erklären. Des Weiteren sollen sie eine Einschätzung geben, ab welcher Schwere von Dürre das Auftreten von Auswirkungen in den verschiedenen NUTS-2-Regionen zu erwarten ist. Vorhersagen konnten dabei nur für NUTS-2-Regionen getroffen werden, in denen ein Index signifikanter Prädiktor für Dürreauswirkungen war. Die vorhergesagten Werte wurden mittels *logit*-Transformation (Formel 1) in Wahrscheinlichkeiten umgerechnet und die Auftrittswahrscheinlichkeit von Dürreauswirkungen im Forst für vier Dürrestufen der Indices dargestellt.

3.3.5 ICP Forest Daten – Voruntersuchungen und Trendanalysen

Im zweiten Teil dieser Arbeit wurde der Zusammenhang zwischen den in Abschnitt 3.2.2.2 vorgestellten Level-I Kronenentlaubungsdaten der ICP Forest als Antwortvariable für Dürreauswirkungen im Forst und den verschiedenen Dürreindices untersucht. Bevor ein Modell angepasst wurde, um diesen Zusammenhang zu untersuchen, wurden die Kronenentlaubungsdaten grafisch und mittels eines nicht-parametrischen Mann-Kendall Tests auf Trend hin untersucht. Die Kronenentlaubungsdaten der vier Hauptbaumarten wurden zuvor auf Autokorrelation analysiert. Anschließend wurden die Zeitreihen der Kronenentlaubung mit der Autokorrelation nach einem Jahr korrigiert. Für die korrigierten Zeitreihen wurde mit der Funktion *mk.test* aus dem Paket *trend* (Pohlert, 2018) sowohl für Gesamtdeutschland als auch für jede NUTS-2-Region ein Mann-Kendall Trendtest durchgeführt. Die Ergebnisse der Regionen mit einer signifikanten Zu- oder Abnahme der Kronenentlaubung wurden für jede der Baumarten grafisch dargestellt.

3.3.6 Linear Mixed Effect Models – ICP Forest Daten

Aufgrund vieler gruppierender Variablen und unregelmäßigen oder kleinen Stichproben sind ökologische Modelle häufig komplex. Zur Analyse solcher Daten eignen sich *linear mixed effect models* (LMMs) (Zuur et al., 2009). LMMs erweitern traditionelle lineare Modelle durch das Aufteilen der Prädiktoren in *fixed* und *random effects*. *Fixed effects* sind die Prädiktoren, deren Einfluss auf die Antwortvariable untersucht werden soll. *Random effects* repräsentieren gruppierende Prädiktoren und charakterisieren die Varianz der Antwortvariablen innerhalb und zwischen den Gruppen (Breslow und Clayton, 1993; Harrison et al., 2018). Der Vorteil von LMMs, im Vergleich zu separaten GLMs für jede NUTS-2 Region, ist unter anderem deren hohe Flexibilität, die Verwendung der Gesamtheit der Daten sowie deutlich weniger Parameter, die geschätzt werden müssen. Außerdem erlauben LMMs die Verwendung von Daten, die nicht voneinander unabhängig sind, welches eine der zentralen Annahmen von GLMs ist (Zuur et al., 2009). In diesem Fall sind das die Kronenentlaubungsdaten verschiedener Stände, die in mehreren aufeinanderfolgenden Jahren aufgenommen wurden.

Um den Zusammenhang zwischen der Kronenentlaubung und den unterschiedlichen Dürreindices mittels LMMs zu untersuchen, wurde das Paket *lme4* (Bates et al., 2015) in R verwendet. Für die Modellselektion wurde ein in Zuur et al. (2009) empfohlener „*top-down*“ Ansatz verwendet:

1. Anpassen eines kompletten Modells (alle *fixed* und *random effects* von Interesse)
2. Optimierung der *random effects* Struktur (Vergleich des AIC verschiedener Modelle mit variierenden *random effects* und konstanter, vollständiger *fixed effect* Struktur, geschätzt nach der *restricted maximum likelihood* (REML) Methode)
3. Optimierung der *fixed effects* Struktur mittels *maximum likelihood* (ML) Methode mit konstanten *random effects*
4. Das finale Modell für jede Baumart erneut mittels REML kalkulieren

Die Antwortvariable Kronenentlaubung wurde für jede der vier Hauptbaumgattungen (*Fagus*, *Picea*, *Pinus*, *Quercus sp.*) separat auf Standebene gemittelt, da alle Prädiktoren ebenfalls nur auf Standebene (oder NUTS-2-Ebene) bestimmt werden konnten. In der Folge wurden die Daten visuell auf Normalverteilung mittels Histogramme und Q-Q-Diagramme untersucht. Aufgrund der deutlichen linksschiefe der Daten wurden diese einer Transformation unterzogen, um eine Normalverteilung zu erreichen. Von verschiedenen Transformationen erzielte eine Wurzeltransformation (+5% je Wert) das bestmögliche Ergebnis.

Ob eine Variable als *fixed* oder *random effect* verwendet wird, hängt von der Forschungsfrage ab. In dieser Arbeit wurde der Zusammenhang zwischen der Antwortvariable Kronenentlaubung und den verschiedenen Dürreindizes untersucht. Die zusätzlichen Parameter der Standorteigenschaften (Höhe, Hangneigung, nFK in drei Bodentiefen), das durchschnittliche Standalter (für jedes Jahr) sowie das Beobachtungsjahr wurden auf Kollinearität analysiert. Die Untersuchung sollte vermeiden, dass keine zwei Prädiktoren als *fixed effect* verwendet werden, die stark miteinander korreliert sind (Problem der Kollinearität, siehe Dormann (2013)). Aufgrund dessen wurde eine Korrelationsmatrix aller Prädiktoren erstellt.

Das Standalter wurde bereits von Klap et al. (2000) und Seidling (2007) als einflussreicher Parameter für Kronenentlaubung identifiziert. Zusätzlich wurden für das komplette Modell Standhöhe (m.a.s.l.), nFK von 0 – 60 cm (mm) sowie Beobachtungsjahr als mögliche *fixed effects* ausgewählt. *Random effects* sind gruppierende Prädiktoren, deren Einfluss auf die Antwortvariable kontrolliert werden soll. Von Interesse ist weniger der Prädiktor an sich (Unterschiede zwischen den Gruppen) als der Effekt des Prädiktors auf die Antwortvariable (Varianz zwischen den Gruppen). Als mögliche *random effects* wurden NUTS-2 ID, Stand ID sowie Beobachtungsjahr ausgewählt. Diese *random effects* können „verschränkt“ (*crossed*) oder „verschachtelt“ (*nested*) sein. In unserem Fall ist Stand ID *nested* in NUTS ID, da jede NUTS-2-Region mehrere, spezifische Stände enthält. Beobachtungsjahr hingegen ist ein *crossed random effect*, da jeder Stand mehrfach für jedes Jahr unseres Datensatzes untersucht wurde. Bei der Einteilung in *crossed* oder *nested random effects* wurde sich an Harrison et al. (2018) orientiert. Das ursprüngliche, komplette Modell hatte die folgende Form:

$$\text{Entlaubung}_{ijt} = X_{ijt} * \beta + Z_{i,jt} * b_i + Z_{ij,t} * b_{ij} + Z_{t,ij} * b_t + \varepsilon_{ijt} \quad (4)$$

Die Antwortvariable ist die Kronenentlaubung für jeden Stand *i* innerhalb der NUTS-2-Region *j* im Jahr *t*. Diese wird durch verschiedene *fixed* und *random effects* beschrieben. X_{ijt} ist die Matrix der *fixed effects* und β ihr Parameter Vektor. $Z_{i,jt}$, $Z_{ij,t}$ und $Z_{t,ij}$ sind die Matrizen der *random effects* von NUTS-2-Region (*j*) und Stand (*ij*) innerhalb jeder NUTS-2 (*nested*) mit den respektiven Parametern b_i und b_{ij} sowie die Matrix des *random effects* für Jahr $Z_{t,ij}$ mit Parameter b_t . Der Ausdruck ε_{ijt} beschreibt den Fehlerterm.

Sechs Modelle mit konstanten *fixed effects* und einer variierenden *random effect* Struktur (Tabelle 3) wurden mittels REML angepasst (Zuur et al., 2009) und über den AIC (*Akaike information criterion*) verglichen. Dies wurde für jede der vier untersuchten Baumgattungen separat durchgeführt.

Tabelle 3: Auswahl der *random effect* Struktur bei gleichbleibender *fixed effect* Struktur für die LMMs. Die *fixed effects* waren Dürreindex, Standalter, Standhöhe (m.a.s.l.), nFK und Beobachtungsjahr.

Modell	Random effects	Modell	Random effects
1	NUTS ID	4	Stand ID + Jahr
2	NUTS ID + Jahr	5	Stand ID <i>nested</i> in NUTS ID
3	Stand ID	6	Stand ID <i>nested</i> in NUTS ID + Jahr

Für die Modelle mit der besten *random effect* Struktur je Baumgattung sollte zunächst der beste Dürreindex ermittelt werden. Untersucht wurden der SMI 25, SMI 180 sowie vier Akkumulationsperioden von SPEI (3, 6, 12 und 24 Monate). Der SPI wurde nicht berücksichtigt, da er nicht den Effekt von Lufttemperatur berücksichtigt, für die ein signifikanter Einfluss auf die Kronenentlaubung vermutet wird. Alle Prädiktoren wurden mittels der Funktion *scale* standardisiert, um in der Folge die Effektstärke besser vergleichen zu können. Für jede Baumart und jeden Dürreindex wurde ein Modell mit konstanter *random effect* Struktur angepasst und mittels ANOVA durch einen *maximum likelihood ratio test* verglichen (Winter, 2013). Auf diese Weise wurde der beste Dürreindex für jede Baumart ermittelt. Anschließend wurden schrittweise alle nicht-signifikanten *fixed effects* auf dieselbe Weise entfernt. Die finalen Modelle wurden dann erneut mittels REML kalkuliert.

Die finalen Modelle jeder Baumart wurden einer kompletten Modelldiagnostik unterzogen. Hier wurde sich vor allem an Dormann (2013) und Winter (2013) orientiert:

- Analyse auf Kollinearität: Wenn Prädiktoren untereinander korreliert sind, führt das zu Unsicherheiten bei der Interpretation des Modelloutputs, da sich die Signifikanzen der Prädiktoren untereinander beeinflussen (Winter, 2013). Um Kollinearität zu vermeiden, wurde im Modell ausschließlich Prädiktoren verwendet, die nicht kollinear waren (Spearman's $\rho < 0.6$; *variance inflation factor (VIF)* für LMMs < 5 , eine konservative Annahme laut Dormann et al. (2013)).
- Analyse der Prädiktoren: Die Verteilung der Prädiktoren wurde grafisch mittels Histogramme überprüft. Normalverteilung von Prädiktoren ist zwar keine Voraussetzung für LMMs, jedoch können extreme Werte eines Prädiktors die Regression dominieren (Dormann, 2013) oder zu Heteroskedastizität der Residuen führen (siehe nächster Punkt).
- Analyse der Residuen: Die Annahme auf Homoskedastizität geht davon aus, dass die Varianz der Daten ungefähr gleichmäßig über die Spanne der vorhergesagten Daten verteilt ist. Dies ist eine der Annahmen für lineare Modelle normalverteilter Daten. Falls nicht, existiert ein Problem der ungleichen Varianzen (Heteroskedastizität). Um auf Homoskedastizität zu untersuchen,

wurden die Schaubilder der normalisierten Pearson-Residuen betrachtet. Diese sollten kein Muster aufweisen (Crawley (2002): „wie Sterne am klaren Nachthimmel“). Des Weiteren wurden die Residuen gegen die einzelnen Prädiktoren dargestellt, um auf Varianzhomogenität der einzelnen Prädiktoren zu untersuchen. In der Folge wurde der SMI 25 und der SMI 180 logarithmiert.

- Analyse auf Normalverteilung der Residuen: Die Analyse wurde grafisch mittels Q-Q-Diagrammen der Residuen durchgeführt.
- Analyse einflussreicher Datenpunkte: Auffällige Datenpunkte wurden über die *Cook's Distance* ermittelt. Werte > 1 bzw. $4/n$ (n = Anzahl der Datenpunkte) werden als auffällig bezeichnet (Dormann, 2013).

Mit der Funktion *r.squaredGLMM* aus dem Paket *MuMIn* (Barton, 2019) wurde die Güte der finalen Modelle jeder Baumart durch *pseudo-R²* Werte bewertet. Zum einen werden *marginal R²* Werte berechnet (Formel 5), welche die erklärte Varianz durch die *fixed effects* beschreiben. Zum anderen werden *conditional R²* Werte berechnet (Formel 6), welche die erklärte Varianz des gesamten Modells beschreiben.

$$R^2(m) = (\sigma f^2) / (\sigma a^2 + \sigma \epsilon^2) \quad (5)$$

$$R^2(c) = (\sigma f^2 + \sigma a^2) / (\sigma f^2 + \sigma a^2 + \sigma \epsilon^2) \quad (6)$$

In diesem Fall ist σf^2 die Varianz der *fixed effects*, σa^2 ist die Varianz der *random effects* und $\sigma \epsilon^2$ beschreibt die Varianz des Fehlerterms.

4 Ergebnisse

Im folgenden Kapitel werden die Ergebnisse der Studie dargestellt und beschrieben. Im ersten Teilabschnitt werden die Trend- und Varianzanalysen der Dürreindices abgebildet. Anschließend werden die Ergebnisse der logistischen Regression der EDII Daten sowie darauf basierenden Dürreerisikokarten für Deutschland präsentiert. Im letzten Teilabschnitt werden die Ergebnisse der LMMs, welche den Zusammenhang zwischen Kronenentlaubung, Dürreindices und weiteren Standortfaktoren beschreiben, dargestellt.

4.1 Dürreindices

Die Zeitreihen der Dürreindices sind in Abbildung 8 als *Spaghetti-plots* abgebildet. Es ist zu erkennen, dass für alle Akkumulationsperioden von SPEI ein negativer Trend vorhanden ist. Für SPEI 24 ist dieser Trend am stärksten. Bei den SMI Indices hat die Trendgerade ebenfalls eine negative Steigung, die jedoch geringer ausfällt. Im Gegensatz dazu weisen die SPI Indices nahezu keine Trends auf.




Abbildung 8: Zeitreihen der Dürreindizes je NUTS-2-Region (schwarze Linie) von 1975-2018 und lineare Trendgerade (rot).

Die Varianz der Indices wurde sowohl grafisch als auch durch einen Zweistichproben-t-Test (*pairwise-t-test*) untersucht. Die Boxplots der Wertebereiche der Indices sind in Abbildung 9 gegeben. Es ist zu erkennen, dass die SPI Indices einen größeren Wertebereich aufweisen und insbesondere für kürzere Akkumulationsperioden extremere Werte als der SPEI annehmen. Die Werte des SMI 25 liegen deutlich unter denen des SMI 180. Der Zweistichproben-t-Test ergab signifikante Unterschiede zwischen den Gruppen SPI und SPEI. Die SPEI Indices unterschieden sich nicht signifikant voneinander. Der SPI 12/24 unterschied sich jeweils vom SPI 3/6. Weiterhin waren SMI 25 und SMI 180 signifikant unterschiedlich.




Abbildung 9: Boxplots des Wertebereichs der Dürreindices.

Die Korrelationsmatrix der zehn Dürreindices sowie des Beobachtungsjahres ist in Abbildung Anhang 1 gegeben. Im Gegensatz zu den SPI Indices sind die SPEI Indices stark negativ mit dem Beobachtungsjahr korreliert und die SMI Bodenfeuchteindices schwach negativ. Dies deckt sich mit den Beobachtungen der linearen Trendlinien aus Abbildung 8.

4.2 EDII Daten

Um einen ersten Überblick über die räumlich-zeitliche Variation der skalierten EDII Einträge im Forstsektor zu erhalten, wurden in die Zeitreihen berichteter Dürreauswirkungen (*TRUE/FALSE*) im Forstsektor seit 1975 für jede NUTS-2-Region dargestellt (Abbildung 10). Als „*TRUE*“ (Auswirkung berichtet) wurden alle Jahre gekennzeichnet, sobald mindestens eine Dürreauswirkung für das jeweilige Jahr berichtet wurde. Für die Stadtstaaten Bremen (DE50) und Hamburg (DE60) waren keine Einträge in der EDII Datenbank vorhanden, weshalb sie von allen weiteren Untersuchungen ausgeschlossen

wurden. Des Weiteren ist zu erkennen, dass die Häufigkeit der Jahre mit berichteten Dürreauswirkungen über die Zeit zunimmt. Eine Übersicht über die Anzahl der Jahre mit mindestens einer berichteten Auswirkung ist für jede NUTS-2-Region in „Tabelle Anhang 1“ gegeben.




Abbildung 10: Zeitreihe berichteter Dürreauswirkungen (skalierte EDII-Daten) für jede NUTS-2-Region seit 1975. „TRUE“, wenn mindestens von einer Dürreauswirkung im Forstsektor in diesem Jahr für diese Region berichtet wurde.

4.2.1 Vorausgehende Analysen des Zusammenhangs zwischen Indices – Auswirkungen (EDII)

Der Zusammenhang zwischen den verschiedenen Dürreindizes und dem prozentualen Anteil der Jahre, in denen mindestens eine Dürreauswirkung berichtet wurde, ist in Abbildung 11 dargestellt. Durch diese Darstellung soll die Hypothese aus Punkt 1 der Fragestellung untersucht werden, ob meteorologische Dürren forstlichen Dürreschäden vorausgehen. Somit wäre in Jahren mit niedrigen Dürreindizes (negative SPI/SPEI; SMI nahe 0) die Wahrscheinlichkeit des Auftretens forstlicher Dürreschäden höher. Die visuelle Beurteilung lässt noch keinen eindeutigen Schluss darauf zu, welcher Index sich am besten zur Vorhersage von Dürreauswirkungen eignet. Es ist jedoch zu erkennen, dass die SPI Indices in Jahren mit positiven Indexwerten (die somit feuchter als das langjährige Mittel waren) einen größeren Anteil

berichteter Dürreauswirkungen aufweisen als der jeweilige SPEI. Das gilt besonders für den SPI 24. Der SMI 25 zeigt mehr Fluktuationen als der SMI 180 auf, auch im Bereich niedriger Indexwerte (0,1 – 0,4).

Eine zusammenfassende Statistik (Mittelwert, Median, Standardabweichung) der Indices für die Gruppen „Jahre mit Auswirkung“, „Jahre ohne Auswirkung“ und „alle Jahre“ ist in Tabelle Anhang 2 gegeben.




Abbildung 11: Zusammenhang zwischen Werten der Dürreindices und prozentualen Anteil der Jahre mit berichteten Auswirkungen (ja/nein). Grafik nach Gauster und Stagge (2019).

4.2.2 Logistische Regression

Für jede NUTS-2-Region wurde eine logistische Regression, mit den EDII Daten als binäre Antwortvariable und den verschiedenen Dürreindices als Prädiktor, gerechnet. Das Ziel war es, für jede NUTS-2-Region das beste logistische Regressionsmodell zu ermitteln. Für die weiteren Analysen wurden ausschließlich Indices verwendet, die ein signifikanter Prädiktor für Dürreauswirkungen in den

jeweiligen NUTS-2-Regionen sind. Abbildung 12 zeigt für jede NUTS-2-Region den Index mit dem besten Modellfit. Für Schleswig-Holstein (DEF0), Thüringen (DEG0), Mecklenburg-Vorpommern (DE80), Niedersachsen (DE91, DE92, DE93, DE94), Detmold (DEA4, NRW), Berlin (DE30) und Sachsen-Anhalt (DEE0) konnte kein signifikanter Index ermittelt werden. Wie bereits erwähnt gibt es für Bremen (DE50) und Hamburg (DE60) keine Einträge in der EDII Datenbank für den Forstsektor, weshalb diese Regionen nicht in die Analyse miteinbezogen werden konnten. Somit konnte für 26 der 38 NUTS-2-Regionen mindestens ein Index als signifikanter Prädiktor für Dürreauswirkungen bestimmt werden. Insgesamt waren 173 von 360 möglichen NUTS-2 – Index Kombinationen signifikant. Der SPEI 24 und SPEI 6 sind in jeweils sechs Regionen der beste Modellprädiktor, der SPEI 3 in fünf, SPEI 12 in vier, SMI 180 in zwei und SPI 6, SPI 12 und SMI 25 in jeweils einer Region.




Abbildung 12: Dürreindex mit dem besten Modellfit (McFaddens *pseudo-R*²) je NUTS-2-Region. Für NUTS-2-Regionen in hellgrau konnte kein signifikanter Index ermittelt werden.

Die Modellgüte der logistischen Regressionsmodelle wurde über McFaddens *pseudo-R*² bestimmt: Für alle signifikanten Indices beträgt die Spanne der Modellgüte 0,11 – 0,59 (0,32 im Mittel). Die höchste Modellgüte haben die Modelle in Baden-Württemberg (max. *pseudo-R*²: 0,46 – 0,59), Rheinland-Pfalz (0,42 – 0,48) und Bayern (0,40 – 0,54), die geringste Modellgüte in Nordrhein-Westfalen (0,21 – 0,31). In Tabelle 4 ist die durchschnittliche Modellgüte für die verschiedenen Indices angegeben. Die Werte decken sich mit den Beobachtungen aus Abbildung 11, dass die SPEI Indices eine bessere Modellanpassung als die SPI Indices aufweisen. Auch der SMI 180 weist durchschnittlich eine höhere Modellgüte als der SMI 25 auf.

Als nächster Schritt wurde untersucht, wie häufig und in welchen NUTS-2-Regionen die Indices signifikante Prädiktoren sind (Tabelle 4). Die Ergebnisse des SPEI 6 und des SPI 24 sind in Abbildung 13 dargestellt: Der SPEI 6 ist in 25 NUTS-2-Regionen signifikant, der SPI 24 nur in neun NUTS-2-Regionen. Insgesamt fällt auf, dass jeder der vier SPEI Indices in mehr Regionen signifikant ist und einen durchschnittlich höheren Modellfit aufweist als der jeweilige SPI. Die kartografischen Darstellungen der weiteren Ergebnisse sind in den Abbildungen 2-3 im Anhang gegeben.

Tabelle 4: Mittelwerte von McFaddens *pseudo-R*² für alle Indices, die in einer NUTS-2-Region ein signifikanter Prädiktor für Dürreauswirkungen sind. Des Weiteren die Anzahl der NUTS-2-Regionen, in denen der Index signifikanter Prädiktor ist.

Index	MW <i>pseudo-R</i> ²	n NUTS-2	Index	MW <i>pseudo-R</i> ²	n NUTS-2
SPEI 3	0,357	19	SPI 6	0,286	18
SPEI 6	0,349	25	SPI 12	0,292	17
SPEI 12	0,326	24	SPI 24	0,198	9
SPEI 24	0,338	18	SMI 180	0,348	15
SPI 3	0,303	14	SMI 25	0,281	14




Abbildung 13: NUTS-2-Regionen, in denen SPEI 6 und SPI 24 signifikanter Prädiktor (logistische Regression, $p \leq 0.05$) für das Auftreten von Dürreauswirkungen (binär: Ja/Nein) sind (GRÜN) bzw. nicht-signifikant sind (ROT). Der SPEI 6 ist mit 25 NUTS-2-Regionen am häufigsten, der SPI 24 mit neun Regionen am seltensten signifikant.

Der Zusammenhang zwischen Dürreindex und der Wahrscheinlichkeit des Auftretens einer berichteten Dürreauswirkung ist in Abbildung 14 beispielhaft für zwei NUTS-2-Regionen dargestellt: Für die NUTS-2-Region DE11 (Stuttgart) ist der SPEI 3 der Index mit dem besten Modellfit ($pseudo-R^2 = 0,59$). Die Wahrscheinlichkeit des Auftretens einer Dürreauswirkung liegt für Indexwerte von -2 bei fast 100%, für -1,3 bei ca. 50% und für Werte von 0 oder größer beinahe bei 0%. Der Median der Wertebereiche des Dürreindex für die beiden Gruppen „Auswirkung berichtet (*impact*)“ und „keine Auswirkung berichtet (*no impact*)“ unterscheidet sich trotz der großen Streuung für „keine Auswirkung“ deutlich voneinander (Abbildung 14 links). Die Modellgüte für SPEI 6 in der Region DEA2 (Köln) ist im Vergleich deutlich niedriger ($pseudo-R^2 = 0,21$). Dies spiegelt sich ebenfalls in Abbildung 14 (rechts) wider: Die Wahrscheinlichkeit des Auftretens einer Auswirkung erreicht auch für stark negative Werte des SPEI 6 nur ca. 75%. Die großen Konfidenzintervalle deuten auf hohe Unsicherheiten hin. Die Indexwerte für die vier berichteten Auswirkungen sind sehr unterschiedlich und der Wertebereich dementsprechend groß. In allen Regionen werden größere Konfidenzintervalle mit steigender Auftrittswahrscheinlichkeit (*likelihood of impact occurrence – LIO*) beobachtet. Für die Abbildungen der restlichen NUTS-2-Regionen mit einem signifikanten Index wird auf den Anhang verwiesen (Abbildung Anhang 4 – 10).




Abbildung 14: Zusammenhang zwischen Index und Wahrscheinlichkeit einer Auswirkung (likelihood). Links: SPEI 3 in NUTS-2 DE11; rechts: SPEI 6 in NUTS-2 DEA2. Die Balkendiagramme bilden den jeweiligen Wertebereich des Index für berichtete Auswirkungen (impact) und keine berichtete Auswirkung (no impact) ab. Abbildungen nach Gauster und Stagge (2019).

4.2.3 ROC Analyse

Die *Area Under Curve* (AUC) Werte liegen zwischen 0,69 – 0,96 für diejenigen Indices, die in den jeweiligen NUTS-2-Regionen signifikanter Prädiktor für Dürreauswirkungen sind (173 Indices in allen NUTS-2-Regionen insgesamt). Diese Ergebnisse sind als hoch einzustufen. Die Kurven weisen zum Teil einen eckigen Verlauf auf. Der Grund hierfür sind zu wenige berichtete Auswirkungen in den NUTS-2-Regionen (4 – 8 Einträge). In 22 von 26 NUTS-2-Regionen fallen die höchste AUC und der höchste McFadden *pseudo-R*² auf den gleichen Index, in vier Regionen unterscheiden sie sich. In einigen NUTS-2-Regionen ist der AUC für mehrere Indices gleich.

In Abbildung 15 sind beispielhaft zwei NUTS-2-Regionen ROC-Kurven dargestellt. Die ROC-Kurve für DE12 (SMI 180) wies zusammen mit DE71 und DE72 die höchste AUC (0,96) auf. Die ROC-Kurve für DEA2 (SPEI 6) mit 0,77 die niedrigste AUC. Selbst ein Wert von 0,77 weist laut Blauhut et al. (2016) noch auf eine gute Modellperformance hin. Alle Abbildungen der Indices mit der jeweils höchsten AUC je NUTS-2-Region sind in den Abbildungen 11 – 17 im Anhang gegeben.




Abbildung 15: ROC-Kurven für die NUTS-2-Regionen DE12 und DEA2 Auf der y-Achse der Anteil korrekt vorhergesagter Auswirkungen (Sensitivität bzw. true positive rate TPR), auf der x-Achse der Anteil falsch vorhergesagter Auswirkungen ($1 - \text{Sensitivität}$ oder false positive rate FPR)

4.2.4 Logistische Regression mit einem Jahr Zeitversatz

Indirekte Auswirkungen von Dürre auf die Waldgesundheit, z.B. die Verbreitung biotischer Schadfaktoren wie Pilze oder Insekten, zeigen sich häufig erst in den Folgejahren des Dürreereignisses. Aufgrund dessen wurde der Zusammenhang zwischen Dürreindizes und den Dürreauswirkungen des Folgejahres untersucht. Im Vergleich zu den Analysen ohne zeitlichen Versatz konnten für deutlich weniger NUTS-2-Regionen ein signifikanter Index ermittelt werden (Abbildung 16): In nur neun von 36 Regionen ist ein Index signifikanter Prädiktor für Dürreauswirkungen. Auch die Modellgütemaße sind deutlich niedriger: McFaddens *pseudo-R*² liegt zwischen 0,14 – 0,34 (0,19 im Mittel) für signifikante Indices. Die durchschnittliche Modellgüte und die Anzahl der NUTS-2-Regionen, in denen die Indices signifikante Prädiktoren für Dürreauswirkungen des Folgejahrs sind, sind in Tabelle 5 angegeben.

Tabelle 5: Mittelwerte von McFaddens *pseudo-R*² für alle Indices, die in einer NUTS-2-Region ein signifikanter Prädiktor für Dürreauswirkungen im Folgejahr waren. Des Weiteren die Anzahl der NUTS-2-Regionen, in denen die Indices signifikanter Prädiktor war

Index	MW Pseudo-R ²	n NUTS-2	Index	MW Pseudo-R ²	n NUTS-2
SPEI 12	0,210	4	SPEI 6	0,182	4
SPEI 24	0,180	2	SPI 24	0,214	1
SPEI 3	0,174	6	SPI 3	0,244	2




Abbildung 16: Rot: NUTS-2-Regionen, in denen keiner der zehn untersuchten Dürreindizes ein signifikanter Prädiktor ($p < 0,05$) für Dürreauswirkungen des Folgejahrs ist. Grün: NUTS-2-Regionen, in denen mindestens ein Dürreindex signifikant ist.

4.2.5 Dürrierisikokarten für Deutschland

In den Abbildungen 17 – 18 ist das mittels logistischer Regression modellierte Dürrierisiko für den Forstsektor in Deutschland dargestellt. Die Karten visualisieren ausgewählte Punkte der modellierten LIO Kurven, um die Vergleichbarkeit zwischen den Regionen zu vereinfachen. Als Dürreindex wurde der SPEI 6 gewählt, da dieser in den meisten NUTS-2-Regionen ein signifikanter Modellprädiktor ist (25, vergleiche Abbildung 13) und im Mittel einen guten Modellfit aufweist (Tabelle 4). Für SPEI 6 Werte bis -1 ist das Dürrierisiko in allen NUTS-2-Regionen mäßig, mit einer LIO von ca. 40% für Teile Baden-Württembergs und Rheinland-Pfalz. Für den SPEI 6 = -1,5 steigt das Dürrierisiko stark an und die Unterschiede zwischen den NUTS-2-Regionen werden deutlicher: Die Regionen im Norden Baden-Württembergs und Bayerns (60–70%) sind am stärksten gefährdet. Zudem weisen die südlichen Regionen Bayerns, Rheinland-Pfalz und Sachsen eine Auftrittswahrscheinlichkeit von Dürreauswirkungen zwischen 45–55% auf. Für Brandenburg, Nordrheinwestfalen und das Saarland (30–40%) ist die berechnete LIO etwas geringer. Für den SPEI = -2 steigt das Risiko in

Baden-Württemberg und Bayern auf 80–95%. In Teilen Hessens, Rheinland-Pfalz und Sachsens ist ein Anstieg auf 70–80% zu verzeichnen. Brandenburg, Teile NRWs und das Saarland weisen Auftretswahrscheinlichkeiten von Dürreauswirkungen von 45–60% auf. Für extreme Dürren (SPEI 6 = -2,5) steigt das Dürrierisiko in einigen NUTS-2-Regionen auf 100% und liegt in allen NUTS-2-Regionen bei über 70% (Abbildung 18).







Abbildung 17: Modellerte Auftretswahrscheinlichkeiten (LIO) von Dürreauswirkungen im Forst in Deutschland für den SPEI 6 (-1; -1,5). Für NUTS-2-Regionen in grau konnte kein signifikanter Dürreindex für die Vorhersage von Dürreauswirkungen ermittelt werden.



Auftrittswahrscheinlichkeit von Auswirkungen (SPEI 6 = -2)



Auftrittswahrscheinlichkeit von Auswirkungen (SPEI 6 = -2.5)




Abbildung 18: Modellierte Auftrittswahrscheinlichkeiten (LIO) von Dürreauswirkungen im Forst in Deutschland für den SPEI 6 (-2; -2,5). Für NUTS-2-Regionen in grau konnte kein signifikanter Dürreindex für die Vorhersage von Dürreauswirkungen ermittelt werden.

4.3 ICP Forest Daten

4.3.1 Trendanalysen

In Abbildung 19 sind die Zeitreihen der gemittelten Kronenentlaubung jeden Jahres für die vier Hauptbaumarten (*Fagus*, *Picea*, *Pinus*, *Quercus sp.*) in Deutschland dargestellt. Auffällig ist, dass bis 2003 für *Quercus sp.* die höchsten Werte der Kronenentlaubung beobachtet wurden. Im Jahr 2003/2004 ist für *Fagus* und *Picea* ein enormer Anstieg der Kronenentlaubung zu beobachten. Die Zeitreihen für *Fagus* und *Picea* scheinen im Gegensatz zu *Pinus* und *Quercus sp.* einen ansteigenden Trend zu verzeichnen. Eine Übersicht über die Anzahl der jeweiligen Bäume pro NUTS-2-Region sowie in Gesamtdeutschland, für die der Parameter Kronenentlaubung erhoben wurde, ist in „Tabelle Anhang 3“ gegeben.




Abbildung 19: Zeitreihen der Kronenentlaubung für die vier Hauptbaumarten (*Fagus*, *Picea*, *Pinus*, *Quercus sp.*) aller beobachteten Bäume in Deutschland.

Die Zeitreihen der gemittelten Kronenentlaubung aller NUTS-2-Regionen sowie ein gewichtetes, gleitendes Mittel (LOESS) sind Abbildung 20 dargestellt. Die Abbildung gibt einen ersten Eindruck der großen räumlichen Variabilität der Kronenentlaubung in jedem Jahr. Weiterhin bestätigt sich die Annahme, dass *Fagus* und *Picea* einen leichten Anstieg der Kronenentlaubung verzeichnen während für *Pinus* und *Quercus sp.* keine längerfristige Zu- oder Abnahme zu beobachten ist.




Abbildung 20: Spaghetti Diagramme der Kronenentlaubung der vier Hauptbaumgattungen (*Fagus*, *Picea*, *Pinus*, *Quercus sp.*) für jede NUTS-2-Region plus gewichtetes, gleitendes Mittel (LOESS)

Um die einzelnen Baumarten auf Trend hin zu untersuchen, wurde ein nicht-parametrischer Mann-Kendall Test durchgeführt. Zuvor wurden die Kronenentlaubungsdaten auf Autokorrelationen (AC) untersucht. Die Ergebnisse sind in Abbildung 21 dargestellt. Bei *Picea* ist eine starke, bei *Pinus* und *Quercus sp.* eine leichte Autokorrelation der Kronenentlaubungsdaten zum Vorjahr zu beobachten. Trotz der signifikanten AC bei *Fagus* nach zwei Jahren, wurden die Kronenentlaubungsdaten nur um die AC nach einem Jahr bereinigt. Die Ergebnisse der nicht-parametrischen Mann-Kendall Trendtests der korrigierten Zeitreihen sind in Tabelle 6 gegeben.

Tabelle 6: Ergebnisse des nicht-parametrischen Mann-Kendall Trendtests der korrigierten (Autokorrelation herausgerechnet) Kronenentlaubungszeitreihen (1990 – 2018).

	<i>Fagus</i>	<i>Picea</i>	<i>Pinus</i>	<i>Quercus sp.</i>
Kendals τ	0,47	0,46	0,13	0,04
p-Wert	0,0003**	0,0004**	0,3354	0,7753




Abbildung 21: Autokorrelation der Kronenentlaubung der vier Hauptbaumarten in Deutschland.

Für *Fagus* und *Picea* war der Test jeweils signifikant und bestätigte die Annahme, dass die Kronenentlaubung seit 1975 signifikant zugenommen hat. Für *Pinus* und *Quercus sp.* fiel der Mann-Kendall Trendtest jeweils nicht-signifikant aus.

Für die räumlich differenzierte Analyse der Entwicklung der Kronenentlaubung in Deutschland wurde für jede Baumart und jede NUTS-2-Region getrennt ein Mann-Kendall Trendtest durchgeführt. Die Daten der Kronenentlaubung wurden ebenfalls um die Autokorrelation von einem Jahr korrigiert. Die Ergebnisse sind grafisch in den Abbildungen 22 und 23 dargestellt. Für *Fagus* ist ein positiver Trend (und somit eine Zunahme der Kronenentlaubung) für 16 von 36 NUTS-2-Regionen zu beobachten. Für lediglich eine NUTS-2-Region (DE22) ist der Trend negativ. Für *Picea* ist in 12 Regionen eine signifikante Zunahme und in vier Regionen eine signifikante Abnahme zu verzeichnen. Dies deckt sich mit dem gesamtdeutschen Trend der Zunahme der Kronenentlaubung bei diesen beiden Baumarten. Bei *Pinus* (7:7) und *Quercus sp.* (8:6) ist das Verhältnis zwischen Zu- und Abnahme ausgeglichen.




Abbildung 22: Mann-Kendall Trendtest für die korrigierten Zeitreihen von *Fagus* und *Picea* pro NUTS-2 Region. Der Farbverlauf gibt die Stärke des Trends an. Positive Werte für Kendall's tau (rot) stehen für eine signifikante Zunahme der Kronenentlaubung in der jeweiligen NUTS-2 Region, negative Werte (grün) für eine signifikante Abnahme. Für grau gekennzeichneten NUTS-2-Regionen konnte kein signifikanter Trend festgestellt werden.




Abbildung 23: Mann-Kendall Trendtest für die korrigierten Zeitreihen von *Pinus* und *Quercus* pro NUTS-2 Region. Der Farbverlauf gibt die Stärke des Trends an. Positive Werte für Kendall's tau (rot) stehen für eine signifikante Zunahme der Kronenentlaubung in der jeweiligen NUTS-2 Region, negative Werte (grün) für eine signifikante Abnahme. Für grau gekennzeichneten NUTS-2-Regionen konnte kein signifikanter Trend festgestellt werden.

In einigen Regionen beruhen die berechneten Trends auf einer geringen Stichprobengröße. Alle NUTS-2-Regionen, in denen Anzahl der untersuchten Bäume geringer als zehn war, sind in Tabelle 7 aufgeführt.

Tabelle 7: NUTS-2-Regionen, in denen die Kronenentlaubung an weniger als zehn Bäumen erhoben wurde.

Baumart	NUTS-2-Regionen mit $n < 10$
<i>Fagus</i>	Brandenburg (DE40), Köln (DEA2), Saarland (DEC0), Dresden (DED2)
<i>Picea</i>	Regionen Lüneburg (DE93), Köln (DEA2), Rheinhessen-Pfalz (DEB3)
<i>Pinus</i>	Stuttgart (DE11), Gießen (DE72), Koblenz (DEB1), Trier (DEB2)
<i>Quercus sp.</i>	Karlsruhe (DE12), Tübingen (DE14), Oberbayern (DE21), Schwaben (DE27), Weser-Ems (DE94), Köln (DEA2), Koblenz (DEB1), Schleswig-Holstein (DEF0)

Eine Übersicht über die durchschnittliche Anzahl der Bäume, an denen die Kronenentlaubung erhoben wurde, ist für alle NUTS-2-Region in „Tabelle Anhang 3“ gegeben.

4.3.2 Linear Mixed Effect Models

4.3.2.1 Untersuchung auf Normalverteilung

Mittels *linear mixed effect models* (LMMs) wurde der Zusammenhang zwischen Kronenentlaubung und verschiedenen Dürreindizes für die vier Hauptbaumarten *Fagus*, *Picea*, *Pinus* und *Quercus sp.* in Deutschland untersucht. Vor der Anpassung eines Modells wurden die auf Stand- und Jahresebene gemittelten Kronenentlaubungsdaten grafisch auf Normalverteilung untersucht (Abbildung 24).




Abbildung 24: Histogramme der Kronenentlaubung der vier Hauptbaumarten in Deutschland.

Aufgrund der Linksschiefe der Verteilungen wurden die Daten wurzeltransformiert (+5% je Datenpunkt), um eine Normalverteilung zu erreichen. Weitere gängige Transformationsverfahren, wie zum Beispiel das logarithmieren, erzielten schlechtere Ergebnisse. Die transformierten Daten sind in den Abbildungen 25 (Histogramme) und 26 (Q-Q-Diagramme) dargestellt. Trotz der Transformation weisen die Daten weiter eine leichte Linksschiefe auf.




Abbildung 25: Histogramme der Wurzeltransformierten Kronenentlaubungsdaten (+5% je Datenpunkt).




Abbildung 26: Q-Q-Diagramme der Wurzeltransformierten Kronenentlaubungsdaten

4.3.2.2 Kollinearität der Prädiktoren

Zu Beginn der Modellselektion wurde ein vollständiges Modell unter Berücksichtigung aller möglichen Variablen, die einen Einfluss auf die Kronenentlaubung haben könnten, aufgesetzt. Um eine Kollinearität zwischen den Prädiktoren zu vermeiden und eine Vorauswahl möglicher *fixed effects* zu treffen, wurde eine Korrelationsmatrix erstellt (Abbildung 27). Die Dürreindizes sind untereinander mehr oder wenig stark positiv korreliert. Wie bereits in Abschnitt 4.1 beobachtet, liegt ein negativer Trend bei den SPEI Indices und ein etwas schwächerer bei den SMI Indices vor. Zusätzlich zu den Indices wurde das Standalter sowie die nFK 60cm (sowohl mit nFK 30cm als auch nFK 90cm stark korreliert) und die Standhöhe als Standortfaktoren ausgewählt. Des Weiteren wurde auch das Beobachtungsjahr als *fixed effect* gewählt, um die Kronenentlaubungsdaten auf linearen Trend zu untersuchen. Bei allen gewählten Prädiktoren war Spearmans $\rho < 0.6$.




Abbildung 27: Korrelationsmatrix mit Spearmans rho der möglichen Prädiktoren (fixed effects)

4.3.2.3 Optimierung der Modellstruktur

Als mögliche *random effects* (gruppierende Prädiktoren) wurden NUTS-2 ID, Stand ID sowie Beobachtungsjahr in Betracht gezogen. Der Effekt von Dürreindex und Standalter sowie weiteren standortspezifischen Faktoren auf die Kronenentlaubung sollte untersucht werden. Dabei sollte jedoch die Varianz zwischen den verschiedenen NUTS-2-Regionen bzw. Ständen und zufälligen Variationen zwischen den Jahren berücksichtigt werden. Für alle Baumarten stellte sich die ursprünglich gewählte *random effect* Struktur mit Stand ID „verschachtelt“ (*nested*) in NUTS ID sowie Beobachtungsjahr als zweiter *crossed random effect* als beste Struktur heraus.

In der Folge wurden für jede Baumart mit der optimierten *random effect* Struktur sechs verschiedene Modelle mittels *maximum likelihood* (ML) Methode angepasst und mittels ANOVA verglichen. Die weiteren *fixed effects* (Standalter, nFK, Höhe des Standes, Jahr) blieben unverändert. Für die Baumarten *Fagus*, *Picea* und *Pinus* ist der logarithmierte SMI 180 der beste Index, für *Quercus sp.* der SPEI 3. Es wurde dennoch der logarithmierte SMI 25 vorgezogen, da der Modellfit nur minimal schlechter ist

(Differenz der AICs <2) und der SMI 25 schwächer mit dem Parameter „Beobachtungsjahr“ korreliert ist.

Um die optimale Modellstruktur für jede Baumart zu ermitteln, wurde schrittweise immer ein Prädiktor entfernt und das nach der ML Methode angepasste Modell mit dem vorherigen Modell verglichen, um alle nicht-signifikanten *fixed effects* zu entfernen. Die endgültigen Modellstrukturen der vier Baumarten lauten:

- *Fagus*: $\text{Log}(\text{SMI } 180) + \text{Standalter} + \text{Jahr} + (1|\text{NUTS ID} / \text{Stand ID}) + (1|\text{Jahr})$
- *Picea*: $\text{Log}(\text{SMI } 180) + \text{Standalter} + \text{nFK } 60 + (1|\text{NUTS ID} / \text{Stand ID}) + (1|\text{Jahr})$
- *Pinus*: $\text{Log}(\text{SMI } 180) + \text{Standalter} + \text{Jahr} + (1|\text{NUTS ID} / \text{Stand ID}) + (1|\text{Jahr})$
- *Quercus sp.*: $\text{Log}(\text{SMI } 25) + \text{Standalter} + (1|\text{NUTS ID} / \text{Stand ID}) + (1|\text{Jahr})$

Für *Fagus* und *Pinus* ist das Beobachtungsjahr ein signifikanter Prädiktor. *Picea* ist die einzige Baumart, für die der Standortfaktor „nFK 60cm“ eine signifikante Modellverbesserung bewirkte.

4.3.2.4 Modelldiagnostik

Die finalen Modelle wurden einer vollständigen Modelldiagnostik unterzogen, als Orientierung dienten die Vorgaben von Dormann (2013) und Winter (2013).

Zusätzlich zu der Analyse der Korrelationsmatrix wurde der maximale *variance inflation factor* (*VIF*) für die finalen Modelle bestimmt. Für alle Modelle lag der *VIF* deutlich unter 5, weshalb kein Problem durch Kollinearität im Modell besteht (Dormann et al., 2013).

Abbildung 28 bildet die Pearson Residuen gegen die angepassten Modellwerte von *Fagus*, *Picea*, *Pinus* und *Quercus sp* ab. Das Streifenmuster entsteht durch die Einteilung der Kronenentlaubung in Klassen, welches nach der Transformation der Daten im unteren Wertebereich noch deutlicher zu erkennen ist als im oberen. Abgesehen davon lässt sich kein Trend in den Residuen Abbildungen bei allen vier Baumarten erkennen.




Abbildung 28: Darstellung der Pearson Residuen gegen die angepassten Modellwerte aller vier Baumarten

Abbildung 29 zeigt die Q-Q-Diagramme der Residuen. In Falle einer Normalverteilung sollten die Residuen entlang der Diagonalen verlaufen. Bei *Fagus* und *Pinus* sind Ausbrüche im oberen Wertebereich zu erkennen und bei *Picea* sowohl am oberen als auch am unteren Ende des Wertebereichs. Lediglich die Residuen von *Quercus sp.* scheinen normalverteilt zu sein.




Abbildung 29: Q-Q-Diagramme der Pearson Residuen der finalen Modelle aller vier Baumarten

Winter (2013) stuft die Untersuchung auf Homoskedastizität der einzelnen Prädiktoren als wichtiger ein als die Annahme einer Normalverteilung der Residuen. Zu diesem Zweck wurden für jede der vier Baumarten die Pearson Residuen der finalen Modelle gegen die einzelnen Prädiktoren dargestellt, um eventuelle Muster zu identifizieren. Die Varianz der Residuen sollte über den Wertebereich der einzelnen Prädiktoren gleichmäßig verteilt sein. Abbildung 30 stellt beispielhaft die Residuen gegen die drei *fixed effects* Standalter, logarithmierter SMI 180 und Beobachtungsjahr von *Fagus* dar. Es sind keine Muster zu erkennen. Die Annahme der Varianzhomogenität der Prädiktoren ist somit bestätigt. Die SMI Indices wurden logarithmiert, da die Residuen zuvor heteroskedastisch waren.

Die Güte des Modells hat sich nach der Transformation sogar noch verbessert. Dies gilt für alle vier Baumarten. Für die entsprechenden Abbildungen von *Picea*, *Pinus* und *Quercus sp.* wird auf den Anhang verwiesen (Abbildungen 18 – 20 im Anhang).




Abbildung 30: Pearson Residuen – Prädiktoren. Baumart: *Fagus*

Die Analyse einflussreicher Datenpunkte wurde über die *Cook's distance* bestimmt. Datenpunkte mit einer *Cook's distance* von >1 werden als auffällig bezeichnet (Cook und Weisberg, 1995). Für *Fagus* und *Picea* wurden keine einflussreichen Datenpunkte angezeigt, für *Pinus* und *Quercus sp.* jeweils drei von 4048 bzw. 2384 Datenpunkten insgesamt. Die Datenpunkte weisen jeweils 0 bzw. 100% Kronenentlaubung bei vergleichbaren Dürreindices auf. Aufgrund der großen Anzahl an Datenpunkten wird der Einfluss dieser Punkte jedoch als gering eingestuft. Dormann (2013) schreibt, dass es „praktisch keine Rechtfertigung [gebe], einen Datenpunkt als „Ausreißer“ zu eliminieren!“

In Tabelle 8 sind einige Modellstatistiken der finalen LMMs der vier Baumarten gegeben. Für die *fixed effects* ist jeweils deren Schätzer, der Standardfehler (S.E.) sowie der p-Wert angegeben. Aufgrund der Standardisierung der Prädiktoren (*fixed effects*) im Modell kann ihr Einfluss auf die Kronenentlaubung direkt miteinander verglichen werden.

Tabelle 8: Schätzer der Parameter inklusive Standardfehler (S.E.) und p-Wert für die *fixed effects* sowie Standardabweichung der *random effects* der linear mixed models (angepasst mit REML). Für die *random effects* wurde jeweils der Anteil erklärter Varianz bei gegebener *fixed effect* Struktur berechnet (Angaben in Prozent). Die *fixed effects* wurden standardisiert, wodurch ihr Einfluss direkt miteinander verglichen werden kann.

Art	Effekt	Gruppe	Term	Schätzer	S.E.	p-Wert
<i>Fagus</i>	fixed	NA	(Intercept)	5,19	0,09	1,87E-38
<i>Fagus</i>	fixed	NA	scale(log(SMI 180))	-0,10	0,02	1,62E-05
<i>Fagus</i>	fixed	NA	scale(Standalter)	0,52	0,03	9,34E-48
<i>Fagus</i>	fixed	NA	scale(Jahr)	0,10	0,04	3,56E-02
<i>Fagus</i>	random	Stand ID:NUTS-2	Std.Dev.	0,64 (9,2%)	NA	NA
<i>Fagus</i>	random	NUTS-2	Std.Dev.	0,34 (4,7%)	NA	NA
<i>Fagus</i>	random	Jahr	Std.Dev.	0,22 (3,1%)	NA	NA
<i>Fagus</i>	random	Residual	Std.Dev.	0,71 (10%)	NA	NA
<i>Picea</i>	fixed	NA	(Intercept)	4,99	0,08	1,40E-35
<i>Picea</i>	fixed	NA	scale(log(SMI 180))	-0,07	0,02	1,92E-04
<i>Picea</i>	fixed	NA	scale(Standalter)	0,63	0,03	4,83E-79
<i>Picea</i>	fixed	NA	scale(nFK 0-60cm)	-0,13	0,05	1,39E-02
<i>Picea</i>	random	Stand ID:NUTS-2	Std.Dev.	0,67 (9,2%)	NA	NA
<i>Picea</i>	random	NUTS-2	Std.Dev.	0,33 (4,4%)	NA	NA
<i>Picea</i>	random	Jahr	Std.Dev.	0,13 (1,8%)	NA	NA
<i>Picea</i>	random	Residual	Std.Dev.	0,74 (10%)	NA	NA
<i>Pinus</i>	fixed	NA	(Intercept)	4,96	0,08	5,57E-39
<i>Pinus</i>	fixed	NA	scale(log(SMI 180))	-0,08	0,02	1,26E-05
<i>Pinus</i>	fixed	NA	scale(Standalter)	0,24	0,04	5,20E-11
<i>Pinus</i>	fixed	NA	scale(Jahr)	-0,10	0,03	1,57E-03
<i>Pinus</i>	random	Stand ID:NUTS-2	Std.Dev.	0,55 (6,9%)	NA	NA
<i>Pinus</i>	random	NUTS-2	Std.Dev.	0,29 (3,5%)	NA	NA
<i>Pinus</i>	random	Jahr	Std.Dev.	0,13 (1,6%)	NA	NA
<i>Pinus</i>	random	Residual	Std.Dev.	0,75 (9,4%)	NA	NA
<i>Quercus sp.</i>	fixed	NA	(Intercept)	5,23	0,11	2,91E-37
<i>Quercus sp.</i>	fixed	NA	scale(log(SMI 25))	-0,07	0,03	2,17E-02
<i>Quercus sp.</i>	fixed	NA	scale(Standalter)	0,43	0,05	1,57E-15
<i>Quercus sp.</i>	random	Stand ID:NUTS-2	Std.Dev.	0,81 (10%)	NA	NA

<i>Quercus sp.</i>	random	NUTS-2	Std.Dev.	0,31 (3,7%)	NA	NA
<i>Quercus sp.</i>	random	Jahr	Std.Dev.	0,25 (3,1%)	NA	NA
<i>Quercus sp.</i>	random	Residual	Std.Dev.	0,80 (10%)	NA	NA
<i>Fagus</i>	$R^2_{\text{marginal}}: 0,21$		$R^2_{\text{conditional}}: 0,63$			
<i>Picea</i>	$R^2_{\text{marginal}}: 0,29$		$R^2_{\text{conditional}}: 0,65$			
<i>Pinus</i>	$R^2_{\text{marginal}}: 0,06$		$R^2_{\text{conditional}}: 0,45$			
<i>Quercus sp.</i>	$R^2_{\text{marginal}}: 0,12$		$R^2_{\text{conditional}}: 0,61$			

Bei allen Modellen erklärt das Standalter deutlich mehr Varianz der Kronenentlaubung als der jeweilige Dürreindex: Bei *Fagus* etwa 5-mal, bei *Picea* 9-mal, bei *Pinus* 3-mal sowie *Quercus sp.* etwa 6-mal so viel. Die Kronenentlaubung nimmt bei allen Baumarten mit zunehmendem Standalter zu (Abbildung 31). Für *Picea* und *Quercus sp.* ist ein etwa linearer Zusammenhang vorhanden, wobei die Stärke des Zusammenhangs bei *Picea* deutlicher ist, da die Werte eine geringere Streuung aufweisen. Die geringste Zunahme der Kronenentlaubung mit dem Alter liegt bei *Pinus* vor. Das gleitende Mittel der Kronenentlaubung sinkt für Bäume über 100 Jahren ab.




Abbildung 31: Zusammenhang zwischen Kronenentlaubung und durchschnittlichem Standalter und gleitendes Mittel (LOESS).

Die Kronenentlaubung nimmt mit zunehmendem Dürreindex leicht ab. Es fällt zudem auf, dass die Kronenentlaubung bei *Fagus* über die Zeit zunimmt (positives Vorzeichen von ‚Jahr‘) während sie bei *Pinus* abnimmt (negatives Vorzeichen). Während der Effekt der Zunahme bei *Fagus* im Einklang mit den Trendanalysen der Kronenentlaubung aus Abschnitt 4.3.1 steht, wurde für *Pinus* zuvor kein negativer Trend beobachtet. Ebenfalls erwartungsgemäß sinkt die Kronenentlaubung leicht mit zunehmender nFK bei *Picea*. Der Zusammenhang zwischen den einzelnen *fixed effects* und der Kronenentlaubung ist in den Abbildungen 21 – 24 im Anhang dargestellt.

Abschließend wurde noch der Anteil erklärter Varianz der *fixed effect* Struktur durch die einzelnen *random effects* berechnet. Die räumlichen Unterschiede zwischen den Ständen bzw. NUTS-2-Regionen erklären zusammen etwa 14% der Varianz (bei *Pinus* nur ca. 10%). Zufällige Unterschiede zwischen den Jahren erklären nur einen geringen Anteil der Varianz (1,6–3,7%). Die Gruppe „*Residual*“ beschreibt den Anteil der Varianz der *fixed effects*, welche nicht durch die *random effects* erklärt werden kann. Er beträgt für alle vier Baumarten ca. 10%.

Über die Funktion *r.squaredGLMM* aus dem Paket *MuMIn* wurde schließlich noch der Anteil erklärter Varianz der Kronenentlaubung durch die gesamte *fixed effect* Struktur (ohne *random effects*) sowie durch die komplette Modellstruktur berechnet. Der Anteil erklärter Varianz durch die *fixed effects* ist bei allen Modellen gering, am niedrigsten für *Pinus* mit 6% erklärter Varianz der Kronenentlaubung. Durch die Betrachtung der kompletten Modellstruktur und somit der Berücksichtigung der erklärten Varianz durch die *random effects* erklären die LMMs von *Fagus*, *Picea* und *Quercus sp.* zwischen 61–65% sowie das von *Pinus* 45% der Varianz der Kronenentlaubung.

5 Diskussion

In diesem Kapitel werden die Ergebnisse aus dem vorherigen Abschnitt diskutiert, bewertet und in Ihrer Relevanz eingeordnet. Dabei wird insbesondere darauf eingegangen, inwiefern sich die in Abschnitt 2 aufgestellten Fragen und Hypothesen beantworten und bewerten lassen. Neben den ermittelten Ergebnissen werden auch die Unsicherheiten der Datengrundlage sowie der angewandten statistischen Methoden diskutiert und die Ergebnisse entsprechend eingeordnet.

5.1 Dürreindices

Ein Teilziel dieser Arbeit ist es, den funktionellen Zusammenhang zwischen verschiedenen Auswirkungsdaten von Dürre und verschiedenen Dürreindices statistisch zu ermitteln und die Indices in Ihrer Aussagekraft untereinander zu vergleichen. Trend- und Varianzanalysen der Indices im Vorfeld der Modellierung sollten dabei einen ersten Eindruck über Wertebereich, Verteilung, zeitlichen Verlauf und Kollinearität der Indices geben. Die grafische Analyse der Zeitreihen der Indices wies auf einen stark negativen Trend für SPEI und einen schwach negativen Trend für SMI hin, während Werte des SPI keinen erkennbaren Trend aufwiesen. Der SPEI berücksichtigt zusätzlich zum Niederschlag die potenzielle Verdunstung auf Basis der Temperatur. Der Anstieg der Oberflächentemperatur in Deutschland und Europa, insbesondere innerhalb der letzten 30 Jahre, führt zu einer Zunahme der potentiellen Verdunstung und somit zu geringeren SPEI Werten (vgl. Abschnitt 1.2). Diese Zunahme der Oberflächentemperatur spiegelt sich auch im modellierten Bodenfeuchteindex SMI wider. Die SPI Indices hingegen weisen keinen zeitlichen Trend auf, da die Sommerniederschläge in Deutschland im Mittel keine signifikante Abnahme aufweisen (Brasseur et al., 2017). Die grafische Analyse auf Trend wird auch durch die Ergebnisse der Korrelationsmatrix gestützt: die SPEI Indices sind stark negativ und die SMI Indices schwach negativ mit dem Beobachtungsjahr korreliert. Die grafische Boxplot Varianzanalyse der Indices weist auf die Problematik bei der Berechnung des SPI hin: bei kürzeren Akkumulationsperioden (drei und sechs Monate) in Regionen mit geringen Niederschlägen können irritierende Ergebnisse entstehen (Lloyd-Hughes und Saunders, 2002; Mishra und Singh, 2010). Dies spiegelt sich im größeren Wertebereich (Werte < -3 & > 3) des SPI wider. Der SMI 25 hat generell geringere Werte als der SMI 180, da der Oberboden zuerst von Dürre betroffen ist und deshalb häufiger austrocknet.

Die Dürreindices sind standardisierte Variablen und treffen somit keine Aussagen über den absoluten Niederschlag oder die absolute Bodenfeuchte in einer Region. Des Weiteren bedingt die Standardisierung, dass die Häufigkeit extremer Ereignisse per Definition in allen Regionen gleich ist (Lloyd-Hughes und Saunders, 2002). Die in dieser Studie verwendeten Indices sind auf Jahres- und NUTS-2-Ebene gemittelt. Für die SPI und SPEI Indices wurden jeweils die Werte der Sommermonate verwendet, da für Dürreauswirkungen im Forst Niederschlagsdefizite und Hitzewellen während der

Vegetationsphase als entscheidend angesehen wurden. Für die SMI Indices wurde das 5%-Perzentil des jeweiligen Jahres aller Punkte innerhalb einer NUTS-2-Region ausgewählt, da die trockenen Extreme für die Dürreauswirkungen als maßgeblich erachtet werden. Die Auswahl der räumlichen- und zeitlichen Ebene erfolgte als Kompromiss zwischen den hochaufgelösten Dürreindices und den gröber aufgelösten Auswirkungsdaten.

5.2 EDII – Datenbank

Im ersten Teil dieser Arbeit wurden das Dürrierisiko der NUTS-2-Regionen über den funktionellen Zusammenhang zwischen Dürreindices und vergangenen Auswirkungen von Dürre bewertet. Die textbasierten, qualitativen Auswirkungsdaten von Dürre im Forstsektor in Deutschland wurden der EDII Datenbank entnommen.

Die EDII Datenbank ist eine recht neue Informationsquelle (Einführung im Jahr 2012). Dürren sind per Definition seltene Ereignisse, weshalb viele Jahre ohne berichtete Auswirkung existieren (Blauhut et al., 2015). Ein Jahr ohne Auswirkung kann zweierlei Gründe haben: 1. Es gab keine Auswirkung oder 2. Die Auswirkung wurde aufgrund mangelnder Berichterstattung oder Datenaufnahme nicht erfasst. Des Weiteren sind die Einträge in der Datenbank zeitlich verzerrt, da die Anzahl der Berichte über die Zeit zunimmt. Dies begründet sich dadurch, dass mehr Medien und Webseiten verfügbar sind und sich das öffentliche Umweltbewusstsein verstärkt hat (Stahl et al., 2016). Dies zeigt sich bei den EDII Einträgen für den Forstsektor besonders nach dem Rekordsommer 2003, was zum einem am gesteigerten öffentlichen Bewusstsein der Problematik und zum anderen in der großen Anzahl überdurchschnittlich warmer Jahre begründet liegen kann (siehe Abschnitt 1.2). Wenn die Datenbank weiter wächst, wird dieser Trend langfristig abnehmen. Zwischen 1975 und 2003 ist die Datengrundlage in vielen Regionen gering. Eine Auswertung auf saisonaler oder monatlicher Ebene könnte sich auch in Zukunft als schwierig gestalten, da nur ein geringer Anteil der forstlichen Einträge zeitlich so genau spezifiziert ist. Die originalen EDII Daten enthielten nur 102 auf NUTS-2-Ebene differenzierte Einträge, was als unzureichend für eine räumlich-zeitliche Analyse auf dieser Ebene angesehen wurde. Aufgrund dessen wurden alle 178 EDII Einträge, die als räumliche Referenz nur die NUTS-1-Ebene hatten, auf NUTS-2-Ebene skaliert. Dadurch kann der Effekt entstehen, dass Auswirkungen möglicherweise eine größere Fläche betreffen als es eigentlich der Fall ist (Blauhut et al., 2015). Eine erhöhte Datenverfügbarkeit in Zukunft könnten Analysen auf NUTS-2-Ebene verbessern.

Die Voruntersuchungen des Zusammenhangs zwischen Dürreindices und Auswirkungsdaten bestätigen die Annahme aus Punkt eins der Fragestellung, dass meteorologische Dürren den berichteten Dürreauswirkungen im Forst vorausgehen, da der Anteil berichteter Auswirkungen in Jahren mit niedrigen Dürreindices deutlich größer ist.

5.3 Logistische Regression

Die im ersten Teil dieser Arbeit verwendete Methodik, die Vulnerabilität einer Region über vergangene Dürreauswirkungen zu definieren, steht im Gegensatz zur „klassischen“ Risikoanalyse. In dieser wird das Dürrierisiko über festgelegte Grenzwerte von meteorologischen Dürreindices definiert, ohne diese Indices und Grenzwerte mit den spezifischen Auswirkungen von Dürre in der Region zu validieren. Die Auftretswahrscheinlichkeit von Dürreauswirkungen im Forst wurde mittels logistischer Regression als eine Funktion von Dürreindices in Deutschland vorhergesagt. Die EDII Daten wurden als binäre Variable betrachtet (Auswirkung Ja/Nein), wodurch keine Aussagen über die Schwere von Dürren gemacht werden können. Die Vorteile liegen in der leichten Implementierung, der geringeren Anzahl subjektiver Entscheidungen, wie zum Beispiel der Zählweise der Einträge, und den begrenzten Unsicherheiten der Analyse (Bachmair et al., 2017). Die Schwere von Dürre wurde in Bachmair et al. (2017) über die Anzahl der Berichte pro Zeitraum bewertet und der funktionelle Zusammenhang zwischen Indices und Auswirkungsdaten unter anderem mit einem *random forest* Modell untersucht. Für diesen methodischen Ansatz fehlte jedoch die Kapazität in dieser Masterarbeit.

Mittels logistischer Regression konnte für 26 der 38 NUTS-2-Regionen mindestens ein signifikanter Index als Prädiktor für Dürreauswirkungen bestimmt werden. Die NUTS-2-Regionen ohne signifikanten Index befinden sich im Zentrum und im Norden Deutschlands. Es ist wahrscheinlich, dass die geringe Anzahl berichteter Auswirkungen (0 – 4) in diesen Regionen unzureichend für ein signifikantes, statistisches Modell sind (Tabelle 9).

Tabelle 9: NUTS-2-Regionen ohne signifikanten Index, Anteil bewaldeter Fläche der zugehörigen Bundesländer und Anzahl der EDII Einträge (*n*) seit 1975

NUTS-2	Bundesland	% Wald	<i>n</i>	NUTS-2	Bundesland	% Wald	<i>n</i>
DEA4	NW	27	4	DEF0	SH	11	3
DE91	NI	25	4	DE30	Berlin	(37 mit BB)	2
DE92	NI	25	3	DE80	MV	24	2
DE93	NI	25	3	DEG0	Thüringen	34	2
DE94	NI	25	3	DE50	Bremen	12	0
DEE0	ST	26	3	DE60	Hamburg	12	0

Die Küstenregionen Deutschlands sind aufgrund ihrer Nähe zu den Meeren und den daraus resultierenden, milderen Temperaturen im Sommer weniger dürregefährdet, was ein Grund für die geringere Anzahl berichteter Dürreauswirkungen ist. Des Weiteren ist ein Großteil der Regionen weniger bewaldet als der Bundesdurchschnitt (32%), was ebenfalls Einfluss auf die geringe Anzahl berichteter Auswirkungen im Forst hat. Die Ausnahme ist Thüringen, für das sich trotz 34% Bewaldung nur zwei Einträge seit 1975 in der Datenbank befinden. Daraufhin stellt sich die Frage, inwiefern die Daten der EDII Datenbank räumlich standardisiert aufgenommen werden. Wenn ein Großteil der

Aufrechterhaltung der Datenbank von einigen wenigen Orten aus geschieht, so ist es wahrscheinlicher, dass mehr Einträge in diesen Regionen und weniger Einträge in anderen Regionen vorgenommen werden.

Die Ergebnisse der logistischen Regressionen bestätigen die Hypothese aus Punkt zwei der Fragestellung, dass sich der SPEI besser als der SPI zur Modellierung von Dürreauswirkungen im Forstsektor eignet. Für jede der vier gewählten Akkumulationsperioden (3, 6, 12 und 24 Monate) ist der SPEI in mehr Regionen signifikant und weist eine höhere, durchschnittliche Modellgüte (McFaddens *pseudo-R*²) auf als der jeweilige SPI. Der SPEI berücksichtigt die Temperatur und somit die potentiellen Evapotranspiration, welche einen entscheidenden Einfluss auf dürreinduzierte Schäden bei Bäumen hat: Hohe Evapotranspiration in Kombination mit einer geringen Bodenwasserverfügbarkeit können zur Störung der hydraulischen Leitfähigkeit im Baum führen. Außerdem begünstigen wärmere Temperaturen sekundäre Dürreauswirkungen im Forst, wie z.B. die Dynamik von Insektenpopulationen (siehe Abschnitt 1.3). Der SMI Bodenfeuchteindex eignen sich ebenfalls weniger gut als der SPEI. Dies könnte am Informationsverlust der Indices durch die grobe räumliche und zeitliche Auflösung liegen (5%-Perzentil pro Jahr und NUTS-2-Region). Weiterhin beschreibt der SMI Bodenfeuchtebedingungen, die jedoch nicht zwangsläufig Auswirkungen auf die Vegetation haben müssen. Verschiedene Arten in unterschiedlichen Entwicklungsstufen reagieren differenziert auf Dürrebedingungen (Zink et al., 2016).

Im dritten Punkt der Fragestellung sollte ermittelt werden, ob ein universeller Index existiert, der sich in allen NUTS-2-Regionen in Deutschland am besten für die Vorhersage der Auftretswahrscheinlichkeiten von Dürreauswirkungen im Forst eignet. Bei der Betrachtung der besten Indices je NUTS-2-Region wird deutlich, dass es keinen Index gibt, der in allen NUTS-2-Regionen den besten Modellfit aufweist. Der beste Index je Region wurde über McFaddens *pseudo-R*² bestimmt. Teilweise sind die Unterschiede zwischen dem besten und zweitbesten Index gering. Die Hypothese, dass längere Akkumulationsperioden von SPEI/SPI geeigneter zur Vorhersage als kürzere sind, konnte zum Teil bestätigt werden: SPEI 6 und SPEI 12 sind in den meisten Regionen signifikant, allerdings weist der SPEI 3 den im Mittel höchsten Modellfit auf. Die verschiedenen SPEI Indices sind alle stark miteinander korreliert (Pearsons $r = 0,75 - 0,98$), weshalb die Unterschiede zwischen den Indices teilweise gering sind. Für die Modellierung von Dürreauswirkungen im Forst scheint generell wichtig, dass die klimatische Wasserbilanz der Sommermonate bzw. des Sommerhalbjahrs während der Vegetationsphase berücksichtigt wird.

Die Modellgüte kann in den meisten Regionen als befriedigend angesehen werden. McFaddens *pseudo-R*² nimmt Werte zwischen 0,21 – 0,59 für die besten Indices je NUTS-2-Region an. Die Werte von McFaddens *pseudo-R*² für logistische Regressionen sind oft kleiner als traditionelle R^2 Werte und werden bereits zwischen 20 – 40% als befriedigend angesehen (McFadden, 1974). Die NUTS-2-Regionen mit dem schlechtesten Modellfit befinden sich in Nordrhein-Westfalen. Auch hier ist die

schlechte Modellgüte wahrscheinlich auf die geringe Stichprobengröße ($n = 4$) zurückzuführen. Die Problematik wurde bei der Betrachtung des Zusammenhangs zwischen Auftretswahrscheinlichkeit (LIO) und Index noch einmal deutlich: Neben der geringen Stichprobengröße war auch der Wertebereich der Dürreindices für die vier berichteten Auswirkungen sehr groß (DEA2: SPEI 6: -2,4; -1,8; -0,7; 0,2; vgl. Abbildung 14), wodurch die Modellunsicherheit stark zunimmt. Die allgemeine Zunahme der Modellunsicherheit mit steigender LIO ist dadurch bedingt, dass extremere Ereignisse seltener auftreten.

5.3.1 ROC-Analyse

Die Leistungsfähigkeit der logistischen Modelle wurde anhand einer ROC-Analyse verglichen. Die AUC dient dabei als Messwert für die Modellgüte: Werte $> 0,7$ deuten auf eine gute, Werte $> 0,9$ auf eine sehr gute Modellperformance hin. In einem Großteil der NUTS-2-Regionen (22 von 26) ist der Index mit dem höchsten *pseudo-R*² und mit der höchsten AUC gleich und bestätigt somit die Hypothese, dass in den meisten NUTS-2-Regionen der SPEI besser als der SPI (und SMI) zur Modellierung der Auftretswahrscheinlichkeit von Dürreauswirkungen geeignet ist. Die sehr hohen AUC Werte für signifikante Indices (0,69 – 0,96) deuten auf gute bis sehr gute Modellperformance der Indices hin. Diese Ergebnisse gilt es jedoch kritisch zu beurteilen, da die geringe Stichprobengröße ($n = 4 - 8$) in den NUTS-2-Regionen als unzureichend angesehen muss. Durch die geringe Anzahl an Auswirkungen entsteht ein eckiger Kurvenverlauf mit nur wenige „Stufen“ in der ROC-Kurve und einem entsprechend großen Standardfehler der AUC-Werte. Eine weitere Auswirkung der geringen Stichprobengröße ist, dass in einigen Regionen mehrere Dürreindices die gleiche AUC haben. Eine Vorgabe für minimale Stichprobengrößen für ROC-Analysen in naturwissenschaftlichen Bereichen konnte nicht ermittelt werden.

5.3.2 Logistische Regression mit einem Jahr Zeitversatz

Im vierten Teil der Fragestellung wurde die Hypothese aufgestellt, dass im Folgejahr einer Dürre vermehrt Auswirkungen im forstlichen Bereich berichtet werden. Deshalb wurde der funktionelle Zusammenhang zwischen den verschiedenen Dürreindices und den Auswirkungsberichten des Folgejahrs untersucht. Mit der gewählten Methodik konnte diese Hypothese jedoch nicht bestätigt werden. Für lediglich neun der 36 NUTS-2-Regionen mit EDII Einträgen wurde ein signifikanter Prädiktor ermittelt. Weiterhin ist die Güte der Modelle mit einem Jahr Zeitversatz deutlich geringer als die Modellgüte ohne zeitlichen Versatz. Eine mögliche Erklärung für dieses Ergebnis könnte die Art der Berichterstattung während und nach Dürrejahre und die damit verbundene Anzahl an Einträgen pro Jahr sein: Die Medien sind während des eigentlichen Dürreereignisses deutlich mehr für die Thematik sensibilisiert als in den Folgejahren. Die Spätfolgen von Dürre im Forstsektor werden somit eventuell gar nicht als solche erkannt oder berichtet. Eine Ausnahme könnten Jahre mit zwei aufeinanderfolgenden, extrem trockenen Perioden bilden, wie es z.B. 2018 und 2019 der Fall ist. Es liegt

die Vermutung nahe, dass der Zusammenhang zwischen Dürreindices und Auswirkungen des Folgejahres aufgrund der beschriebenen Charakteristik der Berichterstattung nicht erfasst werden konnte.

5.3.3 Dürreerisikokarten

Die im letzten Abschnitt des ersten Teils der Auswertung erstellten Dürreerisikokarten sollen idealerweise die Unterschiede zwischen NUTS-2-Regionen in der Reaktion auf Dürreereignisse visualisieren. Des Weiteren sollen sie eine Einschätzung geben, ab welcher Schwere von Dürre das Auftreten von Auswirkungen in den verschiedenen NUTS-2-Regionen zu erwarten ist. Da anhand der aktuellen Datengrundlage in verschiedenen NUTS-2-Regionen unterschiedliche Dürreindices den besten Modellfit aufweisen, wurde der SPEI 6 zur Erstellung der Karten gewählt. Er ist in den meisten Regionen signifikant und besitzt die zweitbeste durchschnittliche Modellgüte. Die Auftretenswahrscheinlichkeit von Auswirkungen für Werte des SPEI 6 bis -1 ist in allen Regionen mäßig (20 – 35%), da Werte bis -1 noch normale Klimaschwankungen beziehungsweise nur eine leichte Dürre beschreiben (Spinoni et al., 2016). Ein räumlicher Unterschied zwischen den Regionen wird erst ab Werten < -1,5 sichtbar, was nach McKee et al. (1993) als schwere Dürre klassifiziert wird: besonders gefährdet sind in Deutschland die nördlichen Regionen Baden-Württembergs und Bayerns, sowie Teile von Rheinland-Pfalz und Hessens. Die südlicheren Gebiete von Bayern und Baden-Württemberg beinhalten die Alpenregion und Mittelgebirge. Durch die größere durchschnittliche Höhe könnten diese Regionen weniger dürregefährdet sein als die Wuchsregionen im Norden und im Zentrum Deutschlands. Des Weiteren fand die stärkste Erwärmung der letzten Jahre in den südlichen Regionen Deutschlands statt. Es bleibt jedoch zu betonen, dass die geringere Auftretenswahrscheinlichkeit in Nordrhein-Westfalen und Brandenburg nicht unbedingt an der höheren Widerstandsfähigkeit der Regionen liegt, sondern durch die zeitliche und räumliche Auflösung der Daten bedingt sein kann. In diesen Regionen ist auch die Modellgüte aufgrund der geringen Stichprobengröße am geringsten.

Allgemein gilt es noch einige Unsicherheiten bei dem gewählten Modellansatz zu beachten: Die Verwendung gemittelter Indices, die Auswertung auf jährlicher Ebene sowie die Skalierung der EDII-Einträge limitieren die Genauigkeit der Ergebnisse, insbesondere die Unterschiede zwischen Regionen und Zeiten mit oder ohne Auswirkungen und den dazugehörigen Dürreindices. Es wurde nur ein Index als Prädiktor gewählt und keine Kombination von z.B. einer lang- und kurzfristigen Akkumulationsperiode, was in vorherigen Studien für einige Sektoren und Regionen als beste Prädiktorkombination identifiziert wurde (Stagge et al., 2015; Blauhut et al., 2016). Auch eine Kombination aus Auswirkungsberichten und klassischen Vulnerabilitätsfaktoren, welche sich in Blauhut et al. (2016) zur Vorhersage von Dürreauswirkungen bewährt hat, könnte die Ergebnisse der Modellierung verbessern. Weiterhin ist der Effekt der Indices eventuell nicht isoliert von anderen Einflüssen, wie z.B. Unterschiede in der Datenaufnahme, Trend zwischen den Jahren oder nicht-linearen Effekten, welche durch die Verwendung von GAM Modellen berücksichtigt werden können (Stagge et

al., 2015). Laut Bachmair et al. (2016b) eignet sich ein *random forest* Modellansatz besonders gut in Regionen mit geringer Datenverfügbarkeit. Die Vulnerabilität der Regionen kann sich über die Zeit verändern und somit auch die funktionellen Zusammenhänge, die ermittelt wurden. In diesem Fall könnte eine wachsende Anzahl an Einträgen im Forstsektor in der EDII Datenbank eine Veränderung des Zusammenhangs zwischen Dürreindices und Auswirkungsberichten bewirken. Die besagten alternativen Modellansätze würden den Rahmen dieser Masterarbeit übersteigen, könnten jedoch für zukünftige Untersuchungen in der Risikoanalyse im Forstsektor anhand von Wirkungsberichten interessant sein.

5.4 ICP Forest Daten

Im zweiten Teil dieser Arbeit wurden Kronenentlaubungsdaten der ICP Forest als Antwortvariable für Dürreauswirkungen im Forst verwendet. Die Kronenentlaubung von Bäumen kann unter anderem direkt oder indirekt durch Wasserstress beeinflusst werden (Seidling, 2007). Mittels LMMs wurde der Zusammenhang zwischen der Kronenentlaubung der vier Hauptbaumarten *Fagus*, *Picea*, *Pinus* und *Quercus sp.* und sechs verschiedenen Dürreindices an über 600 Ständen in Deutschland untersucht.

5.4.1 Datenunsicherheit und Trendanalyse

Die Erhebung der Level-I Daten erfolgt nach dem aktuellen Europäischen Protokoll zur Erhebung der Kronenentlaubung (Eichhorn et al., 2017). Die Subjektivität bei der visuellen Beurteilung der Variablen soll möglichst gering gehalten werden, um Konsistenz und Reproduzierbarkeit der Daten zu gewährleisten. Aufgrund dessen wird ein Qualitätssicherungsprogramm durch Fortbildungslehrgänge durchgeführt. Eickenscheidt und Wellbrock (2014) befanden in ihrer Studie über die Konsistenz der erhobenen Daten während der nationalen Trainingsprogramme zwischen 1992 – 2012, dass zwischen den verschiedenen Beobacherteams die absolute Abweichung vom Durchschnitt aller Jahre bei 4,4% lag. Des Weiteren wurden 94% der Beurteilungen innerhalb einer $\pm 10\%$ Abweichung vom Mittelwert getroffen. Außerdem beobachteten die Autoren eine zunehmende Genauigkeit bei der Bestimmung der Daten im Laufe der Jahre, insbesondere bei *Quercus sp.* und *Picea*. Somit können die Kronenentlaubungsdaten als konsistent genug für Auswertung angesehen werden.

Die Zeitreihen der Kronenentlaubung der vier Hauptbaumarten wurden auf Trends hin untersucht. Bei den Zeitreihen der Kronenentlaubung auf gesamtdeutscher Ebene ist vor allem bei *Fagus* und *Picea* die massive Verschlechterung der Waldgesundheit nach dem Sommer 2003 zu beobachten. Bei allen vier Baumarten ist ein Anstieg der Entlaubung für das Jahr 2018 zu verzeichnen. Dies könnte dadurch begründet sein, dass es das wärmste Jahr seit Beginn der Wetteraufzeichnungen war. Zum Zeitpunkt dieser Studie waren noch keine Daten für das Jahr 2019 vorhanden. Der zweite sehr heiße und trockene Sommer in Folge lässt einen massiven Anstieg der Kronenentlaubung im Jahr 2019 vermuten.

Die Spaghetti Diagramme der Kronenentlaubung zeigen, wie heterogen die Beobachtungen in den verschiedenen Regionen sind und wie groß die zeitliche Variation zwischen den Jahren ist. Dennoch sind gewisse Trends erkennbar. Seit Untersuchungsbeginn 1990 ist ein signifikanter Anstieg der Kronenentlaubung bei *Fagus* und *Picea* zu verzeichnen.

Bei *Picea* könnte der sich häufende, massive Befall der Bäume durch den Borkenkäfer ein Auslöser für den Anstieg sein. Wie in Abschnitt 1.2 bereits erwähnt, waren neun der zehn wärmsten Jahre seit 1881 nach 2000, sechs sogar nach 2010. Die warmen Temperaturen begünstigen ein vermehrtes Larvenwachstum und Überleben der Insekten im Winter. Trockenstress und Hitzewellen senken die Produktion sekundärer Metabolite und machen die Bäume somit anfälliger für den Befall von Insekten. Das statistische Bundesamt gibt einen jährlichen Bericht zur Holzeinschlagsstatistik in Deutschland heraus (Statistisches Bundesamt, 2018). Die darin enthaltenen Daten geben unter anderem Aufschluss über die Menge an jährlich anfallendem Schadholz je Baumart und Bundesland. Aus diesen Daten geht hervor, dass 95% des Schadholzes durch Insekten seit 2005 auf Fichten entfällt (siehe Tabelle Anhang 4). Besonders betroffen in den letzten fünf Jahren sind Bayern und Baden-Württemberg. Eine Übersicht des jährlichen durch Insekten verursachten Schadholzes je Bundesland seit 2005 ist in Abbildung Anhang 25 gegeben.

Bei *Fagus* könnte die gestiegene Kronenentlaubung durch akkumulierende Effekte der dicht aufeinanderfolgenden Dürre- und Trockensommer (2011, 2015, 2018) bedingt sein. Extreme Sommer führen zu einer Beschädigung des Feinwurzel- und Blattwerks. In aufeinanderfolgenden Dürre Jahren sind Buchen besonders gefährdet, da sich die Bäume nicht ausreichend regenerieren können. Zusätzlich kommt im Folgejahr eines trockenen und heißen Sommers die vermehrte Blüte und Fruktifikation als Stressfaktor hinzu, da diese in großem Umfang Reservestoffe bindet (Sutmöller et al., 2008; Eickenscheidt et al., 2019). Des Weiteren wurden bei *Fagus* in den letzten Jahren vermehrte Schäden durch Insekten beobachtet. Der Buchenprachtkäfer (*Agrilus viridis*) ist eine wärmeliebende Art, der ausschließlich vorgeschädigte oder durch Trockenheit geschwächte Bäume befällt. Die Entwicklung der Larven dauert normalerweise 1-2 Jahre, jedoch war die Entwicklung im Trockensommer 2015 innerhalb eines Jahres abgeschlossen. Zusätzlich waren die Bäume geschwächt, was den Befall der Buchen im Folgejahr 2016 begünstigte und eine Erklärung für den Anstieg der Kronenentlaubung im Jahr 2016 sein könnte. Durch Trockenereignisse wie 2015 werden Buchenbestände großflächig anfällig. Eine mehrjährige Schwächung durch aufeinanderfolgende Dürrejahre, wie z.B. 2018 und 2019, könnte eine Massenvermehrung der Käfer zur Folge haben (Gößwein et al., 2017).

Der nicht-signifikante, deutschlandweite Trend der Kronenentlaubung bei *Pinus* und *Quercus sp.* könnte auf die in Abschnitt 1.3 beschriebene, generell höhere Dürretoleranz der Arten zurückzuführen sein. Um die Entwicklung der Kronenentlaubung der Baumarten räumlich differenzierter zu untersuchen, wurde in jeder NUTS-2-Region ein nicht-parametrischer Mann-Kendall Trendtest durchgeführt. Zuvor wurden die Zeitreihen um die Autokorrelation von einem Jahr bereinigt. Diese war besonders bei *Picea*

im Folgejahr sehr hoch, was ebenfalls auf den Befall durch Insekten zurückzuführen sein könnte: In den Folgejahren nach einer Dürre befallen Borkenkäfer vor allem geschwächte Bäume (Anderegg et al., 2015). Für *Pinus* und *Quercus sp.* ist das Verhältnis von Regionen mit Zunahme und Regionen mit Abnahme der Kronenentlaubung relativ ausgeglichen, was eine Erklärung für den nicht-vorhandenen deutschlandweiten Trend sein könnte.

Die Hypothese aus Punkt fünf der Fragestellung, dass die Baumarten unterschiedliche räumliche und zeitliche Dynamiken der Kronenentlaubung aufweisen, konnte im Allgemeinen bestätigt werden. Allerdings sind einige Einschränkungen zu beachten: Die berechneten Trends basieren ausschließlich auf den Kronenentlaubungsdaten. Der starke Einfluss des Baumalters auf die Kronenentlaubung wurde bereits in früheren Studien hervorgehoben (Klap et al., 2000; Seidling, 2007). Altersunabhängige räumlich-zeitliche Trends sind essentiell um Regionen zu identifizieren, wo die hohe durchschnittliche Kronenentlaubung anderen Faktoren als dem Baumalter, wie z.B. dem Klima, zuzuschreiben sind (Eickenscheidt et al., 2019). Weiterhin beruhen die berechneten Trends in einigen Regionen auf einer geringer Stichprobengröße. Somit liegt in der Analyse eine größere Unsicherheit und die berechneten Trends können eventuell als nicht repräsentativ für die gesamte NUTS-2-Region angesehen werden. Dies gilt besonders für *Quercus sp.*. Seidling (2007) verwendet in seinen Untersuchungen nur dann einen Stand für eine Baumart, wenn mindestens vier Individuen kontinuierlich über die Zeit aufgenommen wurden.

Die berechneten Trends liefern somit keine Erklärung für Schäden an Bäumen, welche ausschließlich auf der artenspezifischen Reaktion auf Dürre basiert. Nichtsdestotrotz geben die berechneten Trends eine Einschätzung der Entwicklung der Kronenentlaubung und weisen auf sowohl räumliche als auch artenspezifische Unterschiede hin. Eine Modellierung mit alterskorrigierten Kronenentlaubungsdaten hätte den Umfang dieser Arbeit überstiegen.

5.4.2 Linear Mixed Effect Models

Der Zusammenhang zwischen den Kronenentlaubungsdaten und Dürreindices wurde mittels LMMs untersucht, entgegen der ursprünglichen Idee, für jede NUTS-2-Region und jede Baumart ein GLM aufzusetzen. Dies wäre aufgrund der kleinen Stichprobenanzahl und der hohen Anzahl zu schätzender Parameter statistisch nicht durchführbar gewesen. Mittels LMMs konnte der Einfluss der Dürreindices sowie weitere standortspezifische Faktoren verglichen werden und gleichzeitig die räumliche Varianz zwischen den Ständen bzw. NUTS-2-Regionen und die zeitliche Varianz zwischen den Jahren berücksichtigt werden.

Die Kronenentlaubungsdaten wurden wurzeltransformiert (+5% je Datenpunkt), um eine Normalverteilung zu erreichen. Trotz der Transformation weisen die Daten eine leichte Linksschiefe auf, jedoch bemerkt Winter (2013) in seiner Anleitung zu Modelldiagnostik, dass lineare Modelle relativ robust gegenüber Verletzungen der Normalitätsannahme sind. Die Optimierung der *random effect*

Struktur ergibt für alle Baumarten das gleiche Ergebnis: neben der Varianz zwischen den NUTS-2-Regionen müssen auch die Varianz zwischen den einzelnen Ständen sowie nicht-lineare Trends zwischen den Jahren berücksichtigt werden, was ein erstes Anzeichen dafür ist, dass räumliche und zeitliche Unterschiede bei der Kronenentlaubung einen großen Einfluss haben. Als *fixed effects* wurden diejenigen Variablen gewählt, von denen ein Einfluss auf die Kronenentlaubung erwartet wurde bzw. untersucht werden sollte. Dies waren in erster Linie die Dürreindices. Der SPI wurde in diesem Modellansatz nicht verwendet, da sich SPEI und SMI im ersten Teil der Arbeit als deutlich bessere Indices für die Vorhersage von Dürreauswirkungen im Forst erwiesen haben. Bedingt durch die ursprünglich gewählte Methodik waren die Dürreindices nur auf NUTS-2-Ebene gemittelt vorhanden. Eine räumlich differenziertere Auflösung wäre interessant gewesen, um noch besser die Bedingungen an den jeweiligen Standorten zu beschreiben. Für die erneute Berechnung der Indices fehlte jedoch die Kapazität in dieser Arbeit. Als zweiter *fixed effect* wurde das Standalter gewählt. Wie bereits erwähnt wurde dessen Einfluss auf die Kronenentlaubung in vorherigen Studien ermittelt (Klap et al., 2000; Seidling, 2007). Die Bestimmung erfolgt nach unterschiedlichen Methoden, die jeweils ihre Unsicherheiten haben: 1. Gesichertes Datum der Standgründung, 2. Baumstümpfe, 3. Altersbestimmung der untersten Zweige, 4. Zuwachsbohrer und Stammscheiben außerhalb des Standes, 5. Genaue Bestimmung (meist nicht möglich) oder 6. Schätzung ohne genauere Informationen (Eichhorn et al., 2017). Neben der Unsicherheit der jeweiligen Methode repräsentiert das Standalter nur den Wert für die dominierende Baumart des Standes. Trotz aller Ungenauigkeiten bei der Schätzung bemerkt Eichhorn et al. (2017), dass selbst eine grobe Altersabschätzungen einen erheblichen Anteil der Entlaubungsvarianz erklärt. Die nutzbare Feldkapazität liefert nur einen festen, standortspezifischen Wert und macht somit keine Aussage über variable Bodenfeuchte. Die Höhe des Standes wurde in Klap et al. (2000) als signifikant bestimmt. Das Beobachtungsjahr wurde ebenfalls als *fixed effect* betrachtet, um auf linearen Trend der Kronenentlaubungsdaten zu untersuchen.

Für *Fagus*, *Picea* und *Pinus* ist der SMI 180, für *Quercus sp.* der SMI 25 der Index mit der besten Modellanpassung. Eine Erklärung könnte sein, dass die Bodenfeuchtebedingungen ein entscheidender Faktor für die Kronenentlaubung sind. Das Ergebnis für *Quercus sp.* ist ein wenig überraschend, da *Quercus sp.* den Großteil ihrer Wurzeln in ca. 60 cm Tiefe haben. Eine höhere räumliche Auflösung der Indices könnte die Modellergebnisse verbessern. Zusätzlich wären Informationen über die absolute Bodenfeuchte zum Zeitpunkt der Datenaufnahme interessant.

Wie erwartet ist das Standalter bei allen vier Baumarten signifikant und erklärte in allen vier Modellen den größten Anteil der Varianz der Kronenentlaubung. Für *Pinus* ist der Einfluss des Alters am geringsten, was sich mit den Ergebnissen von Eickenscheidt et al. aus dem Jahr 2019 deckt. Der artenspezifische Zusammenhang zwischen Entlaubung und Alter kann in erster Linie auf den für die entsprechenden Arten typischen Bedarf an Licht, Bestandssituation, Bestandsentwicklung und Waldbewirtschaftung (Beschneiden, Ausdünnen, Fällen) zurückgeführt werden (Eickenscheidt et al.,

2019). Buchen (*Fagus*) gelten allgemein als schattentolerant, somit könnte die Zunahme der Kronenentlaubung auf das langsame aber kontinuierliche vertikale Wachstum zurückzuführen sein (Pretzsch et al., 2015). Junge Buchen wachsen in Deutschland häufig in schattigeren Bereichen, während ältere meist auf gerodeten Flächen mit natürlicher Verjüngung wachsen. Kiefern (*Pinus*) und Eichen (*Quercus sp.*) sind lichtanspruchsvolle Pflanzen, welche neben einem stärkeren vertikalen Wachstum bei Jungpflanzen jedoch eine abnehmende Wachstumsrate mit zunehmendem Alter zeigen (Pretzsch et al., 2015). Fichten (*Picea*) zählen zu den halbschattigen Baumarten. Laut Eickenscheidt et al. (2019) sind alte Fichten häufig auf Standorten mit extremen klimatischen Bedingungen oder schlechter Qualität zu finden (z.B. Bayerische Alpen), weshalb eine Verwechslung zwischen Standortbedingungen und Alter nicht ausgeschlossen werden kann. Verschiedene Autoren haben eine akkumulierende Wirkung mehrerer Stressfaktoren mit zunehmendem Alter vorgeschlagen, was eine erhöhte Empfindlichkeit bei älteren im Vergleich zu jüngeren Bäumen bedingt (Klap et al., 2000; Seidling und Mues, 2005). In der Studie von Eickenscheidt et al. (2019) wurden weiterhin Altersanpassungen für die Schätzung des zeitlichen Trends vorgenommen: diese bestätigten die Annahme, dass Unterschiede in der Kronenentlaubung zwischen den Baumarten vor allem altersbedingt sind: *Fagus*, *Picea* und *Quercus sp.* zeigen bei gleichem Alter (150 Jahre) eine ähnliche Entlaubung, einzig die Werte von *Pinus* sind geringer. Die Autoren schließen daraus, dass das Standalter sowie der artenspezifische Zusammenhang zwischen Entlaubung und Alter den generellen Grad der Entlaubung bestimmen und Fluktuationen wetterbedingt sind. Des Weiteren empfehlen sie altersunabhängige Zeitreihen, um Regionen mit längerfristiger hoher Entlaubung zu identifizieren, in denen der Effekt nicht primär auf den Alterseffekt zurückzuführen ist.

Das Beobachtungsjahr ist nur bei *Fagus* und *Pinus* signifikant. Für *Fagus* wurde eine leichte Zunahme der Entlaubung mit der Zeit festgestellt, was sich mit den zuvor getätigten Trendanalysen deckt. Für *Picea* ist das Jahr nicht signifikant, obwohl zuvor ein positiver Mann-Kendall Trend bestimmt wurde. Möglicherweise wird der lineare Trend bereits durch den SMI Index erklärt, der ebenfalls einen leicht negativen Trend aufweist. Im Gegensatz dazu wurde für *Pinus* das Jahr als signifikanter Prädiktor bestimmt, obwohl zuvor der Mann-Kendall Test nicht signifikant ausgefallen war. Der Effekt ist hier umgekehrt als bei *Fagus*: Mit zunehmender Zeit nimmt die Kronenentlaubung bei *Pinus* ab. Allgemein kann eine Verjüngung der Stände eine altersbedingte Abnahme der Kronenentlaubung bewirken, was zu einem negativen Trend der Kronenentlaubung über die Zeit führen kann.

Die beiden standortspezifischen Faktoren nutzbare Feldkapazität und Höhe sind bis auf die nFK bei *Picea* in keinem Modell signifikant. Dies könnte darin begründet sein, dass sie nicht über die Zeit variieren und somit nur Unterschiede zwischen den Standorten beschreiben. Die Varianz zwischen den Ständen wird jedoch bereits durch die *random effect* Struktur berücksichtigt.

Die finalen Modelle jeder Baumart wurden einer vollständigen Modelldiagnostik unterzogen. Die Abbildungen der Residuen sollten keine erkennbaren Muster aufweisen. Die Q-Q-Diagramme deuten

auf leichte Abweichungen der Normalverteilung bei *Fagus*, *Picea* und *Pinus* hin. Die Annahme auf Normalität der Residuen wird von Winter (2013) als die unwichtigste Modellannahme deklariert mit dem Verweis darauf, dass Gelman und Hill (2007) nicht einmal die Analyse auf Normalität der Residuen empfehlen. Auch in Dormann (2013) wird dieser Punkt nicht in der klassischen Modelldiagnostik erwähnt. In den XY Diagrammen der Residuen gegen die jeweiligen *fixed effects* der Modelle sind bei allen Baumarten keine Muster zu erkennen, weshalb die Ergebnisse der Modellierung als statistisch korrekt angesehen werden.

Schlussendlich wurde der Anteil der erklärten Varianz der Kronenentlaubungsdaten berechnet, einmal nur durch die *fixed effect* Struktur und einmal durch das gesamte Modell. Ohne Berücksichtigung der räumlichen und zeitlichen Varianz haben die Modelle nur eine geringe Erklärungskraft: 6% für *Pinus*, 12% für *Quercus sp.*, 21% für *Fagus* und 29% für *Picea*. Der Anteil erklärter Varianz der *fixed effects* wird vor allem durch den Anteil erklärter Varianz des Standalters bestimmt, weshalb der Wert für *Pinus* der niedrigste ist. Der Anteil erklärter Varianz durch die Dürreindices ist im Vergleich zum Standalter bei allen Baumarten gering. Das Gleiche gilt für die Variablen Jahr und nFK (in den Modellen, wo diese signifikant sind). Berücksichtigt man die komplette Modellstruktur, so erklären die Modelle für *Fagus*, *Picea* und *Quercus sp.* zwischen 61 – 65% der Varianz der Kronenentlaubung, das für *Pinus* immerhin noch 45%. Die räumliche Heterogenität (Stand ID und NUTS Region) erklärt einen größeren Anteil der Varianz (10 – 14%) der *fixed effects* als nicht-lineare Trends zwischen den Jahren (2 – 4%). Der Anteil nicht erklärter Varianz (*Residuals*) der gewählten *fixed effect* Struktur war bei allen Modellen mit 10% gering.

Abschließend müssen noch einige Dinge über den generellen Modellansatz und die Wahl der Prädiktoren diskutiert werden. Durch die Auswertung auf jährlicher Ebene können keine Aussagen über den Einfluss des Auftretens von Dürren im Jahresverlauf gemacht werden, welches von mehreren Autoren als entscheidend für die Art und Schwere der Auswirkungen identifiziert wurde (Taeger et al., 2013; Forner et al., 2018). Die Auswirkungen von Dürren im Forst können besonders schwer sein, wenn das Ereignis früh im Jahr zu Beginn der Vegetationsphase auftritt. Ein möglicher Ansatz, diesen Einfluss zu berücksichtigen, könnte eine geänderte Wahl der Dürreindices sein. Anstatt für jedes Jahr das 5% Quantil des SMI bzw. den SPEI eines festen Monats zu wählen, müsste für jedes Jahr und jeden Stand individuell beurteilt werden, zu welchem Zeitpunkt die klimatischen bzw. Bodenfeuchtebedingungen besonders trocken waren. Der jeweilige Monat bzw. Zeitabschnitt könnte als Faktor für das Auftreten der Dürre im Jahresverlauf berücksichtigt werden.

Weiterhin gibt es zusätzliche Einflüsse auf die Kronenentlaubung, die nicht berücksichtigt wurden, zum Beispiel Luftverschmutzung (Ozon O₃, Schwefeldioxid SO₂, Stickstoffdioxid NO₂, Ammoniak NH₃) und die Deposition von Stickstoff und Säuren (Klap et al., 2000). Des Weiteren waren keine Daten über den Befall der Bäume mit Insekten und Pilzen vorhanden, welche als indirekte Auswirkung von Dürre einen massiven Einfluss auf die Waldgesundheit haben können. Zu guter Letzt schreiben Suttmöller et

al. (2008) in ihrer Studie über den Einfluss des Klimawandels auf die Buchenwälder in Deutschland, dass klimatische Informationen alleine nicht ausreichen, um die Entwicklung der Buche oder anderer Baumarten an klimatische Veränderungen zu bewerten. Die natürlichen Verbreitungsgrenzen sind oft ungewiss und künstliche Verbreitungsgrenzen werden ebenso wie Extremstandorte vernachlässigt. Außerdem werden die Konkurrenzeinflüsse anderer Baumarten nicht berücksichtigt. Des Weiteren findet der lokale Bodenwasserhaushalt keine Beachtung.

Es bleibt jedoch festzuhalten, dass jedes Modell nur eine Vereinfachung der Realität darstellt. Die Limitierungen der Methodik basieren auf der Komplexität von natürlichen Systemen. Ökosysteme werden von einer Vielzahl an Faktoren beeinflusst, und der Versuch alle miteinzubeziehen, würde bedeuten die Realität nachzeichnen zu wollen. Der Fokus dieser Arbeit lag nicht darauf, ein perfektes Modell für Dürreauswirkungen im Forst zu bestimmen, sondern verschiedene Auswirkungsdaten von Dürre auf die Forstwirtschaft in Deutschland zu sammeln und die Eignung verschiedener Dürreindices zur Vorhersage der Dürreauswirkungen zu vergleichen.

6 Schlussfolgerungen und Ausblick

Eine Vielzahl von Regionen in Deutschland wurde in den letzten Jahrzehnten immer häufiger von Dürre betroffen, was auch in weitreichenden Auswirkungen im Forstsektor resultierte. In dieser Arbeit wurden verschiedene Informationen zu Auswirkungen von Dürre im Forstsektor in Deutschland zusammengetragen, um den funktionellen Zusammenhang zwischen den Dürreauswirkungen und verschiedenen Dürreindices zu untersuchen.

Im ersten Teil der Studie wurden die Vulnerabilität und das Dürrierisiko durch den Zusammenhang zwischen den Dürreindices und textbasierten Auswirkungsdaten der EDII Datenbank untersucht. Mittels logistischer Regression wurde die Auftrittswahrscheinlichkeit von Dürreauswirkungen für jede NUTS-2-Region in Deutschland modelliert und die verschiedenen Dürreindices in ihrer Modellgüte miteinander verglichen. Die Ergebnisse lassen darauf schließen, dass die Berücksichtigung der Temperatur für forstliche Dürreauswirkungen essenziell ist, da der SPEI sowohl in mehr Regionen signifikant ist als auch eine im Mittel bessere Modellgüte als der SPI (und SMI) aufweist. Zwar gibt es keinen Index, der für alle Regionen die beste Modellanpassung hat, jedoch scheint die Betrachtung der klimatischen Wasserbilanz des Sommerhalbjahrs während der Vegetationsperiode entscheidend zu sein, da der SPEI 6 am häufigsten ein signifikanter Prädiktor für die Modellierung der Auftrittswahrscheinlichkeit von Dürreauswirkungen war. Die Charakteristik der zeitversetzten Reaktion von forstlichen Systemen auf Dürreauswirkungen ist durch diese Methodik schwer zu erfassen, da die Medienpräsenz vor allem während der Dürreereignisse besonders hoch ist und über Auswirkungen in den Folgejahren möglicherweise weniger berichtet wird. Die erstellten Dürrierisikokarten weisen die niederen, nördlichen Wuchsregionen von Baden-Württemberg und Bayern als besonders gefährdet aus, allerdings ist bei schweren Dürreereignissen ($\text{SPEI} < -2$) auch in vielen Teilen West- und Ostdeutschlands mit Auswirkungen zu rechnen. Aufgrund der extremen Charakteristik von Dürren treten diese per Definition selten auf. Des Weiteren ist die EDII Datenbank eine recht neue Informationsquelle. Somit sind die Anzahl der berichteten Auswirkungen in vielen Regionen limitierend für die Modellgüte bzw. die Bestimmung signifikanter Indices. Die Regionen ohne signifikanten Index sind nicht unbedingt resistenter gegenüber Dürre. Während in Teilen Norddeutschlands aufgrund des gemäßigteren Klimas und der geringeren Bewaldung weniger Dürreauswirkungen im Forst zu erwarten waren, konnten in Zentraldeutschland (Thüringen, Sachsen-Anhalt, Nordhessen) wegen der geringen Stichprobengröße keine signifikanten Indices für die Vorhersage von Dürreauswirkungen ermittelt werden. Aufgrund dieser Tatsache sind die Aufrechterhaltung und Pflege der Datenbank für zukünftige Untersuchungen essentiell. Nur eine konsistente Datenaufnahme in allen Regionen ermöglicht die Ermittlung von räumlichen und zeitlichen Trends im Auftreten von Dürreauswirkungen. Für nachfolgende Untersuchungen könnte die Bewertung der Vulnerabilität durch eine Kombination mit einer klassischer Vulnerabilitätsanalyse, wie in Blauhut et al. (2016), interessant sein: Zusätzlich zu den

Auswirkungsdaten können verschiedene Vulnerabilitätsfaktoren für jede Region ermittelt und gewichtet werden. Des Weiteren könnte versucht werden, die Schwere von Dürreereignissen mittels alternativer statistischer Methoden, wie z.B. einem *random forest* Modell, zu untersuchen. Ebenfalls interessant wäre zu sehen, ob eine Neuberechnung der Indices je NUTS-2-Region zu unterschiedlichen Ergebnissen führen würde, wenn ausschließlich Rasterzellen zur Berechnung verwendet würden, die größtenteils bewaldete Flächen enthalten. Eine Möglichkeit, um die Problematik der geringen Stichprobengröße zu verbessern, könnte das Clustern der forstlichen Auswirkungsdaten sein. Die Zusammenfassung der Daten auf einer höheren räumlichen Ebene könnte jedoch die Bestimmung eines repräsentativen Dürreindices für die gesamte Fläche erschweren. Eine Auswertung auf saisonaler oder monatlicher Ebene könnte sich auch in Zukunft als schwierig gestalten, da forstliche Einträge der EDII Datenbank selten zeitlich so genau spezifiziert werden. Die ermittelten Auswirkungsfunktionen könnten Echtzeit Monitoring und Frühwarnsysteme verbessern, um operative Entscheidungen während Dürreereignissen zu unterstützen und die langzeitliche Dürreplanung zu verbessern.

Im zweiten Teil der Arbeit wurden Kronenentlaubungsdaten der ICP Forest als Weiser für die Waldgesundheit verwendet, um Unterschiede in der Reaktion der Baumarten *Fagus sylvatica*, *Picea alba*, *Pinus sylvestris* und *Quercus sp.* auf Dürre zu ermitteln. Seit 1990 ist vor allem bei *Fagus* und *Picea* eine Zunahme der Kronenentlaubung in mehreren Regionen in Deutschland zu beobachten, während bei *Pinus* und *Quercus sp.* der Anteil von Regionen mit zunehmendem, abnehmendem oder keinem Trend relativ ausgeglichen ist. Die Ergebnisse der *linear mixed effect models* identifizierten die Bodenfeuchteindices SMI 180 für *Fagus*, *Picea* und *Pinus* und SMI 25 für *Quercus sp.* als beste Indices zur Beschreibung der Kronenentlaubung, was darauf schließen lässt, dass die Bodenfeuchtebedingungen entscheidend für die Kronenentlaubung sind. Im Vergleich zum durchschnittlichen Standalter erklären die Dürreindices jedoch recht wenig Varianz der Kronenentlaubungsdaten. Das Standalter ist bei allen vier Baumarten der Prädiktor mit der größten Erklärungskraft. Die generelle Zunahme der Entlaubung mit zunehmendem Alter könnte durch die Akkumulation mehrerer Stressfaktoren bedingt sein. Der Zusammenhang zwischen Alter und Entlaubung ist artenspezifisch und bei *Pinus* am geringsten, weshalb die Güte der kompletten Modellstruktur ebenfalls am geringsten ist. Das Standalter sowie der artenspezifische Zusammenhang zwischen Entlaubung und Alter bestimmen somit den generellen Grad der Entlaubung, während Fluktuationen durch klimatische Bedingungen wie Dürre bedingt sind. Der starke Einfluss der standortspezifischen Unterschiede wurde durch die Wahl der *random effects* Stand ID und NUTS-2 ID im Modell bestätigt. Untersuchungen mit den ICP Forest Daten werden auch in Zukunft möglich sein, da diese Daten im Zuge der Waldzustandsberichte einmal im Jahr erhoben werden. Es wäre interessant zu untersuchen, ob die Erklärungskraft der Dürreindices steigt, wenn diese präziser die Bedingungen am jeweiligen Stand zum Zeitpunkt der Datenaufnahme beschreiben würden. Es könnten diejenigen Rasterzellen verwendet werden, welche den jeweiligen Ständen am nächsten liegen. Des Weiteren wären Informationen über die absolute Bodenfeuchte zum Zeitpunkt der Datenaufnahme interessant. Das Helmholtz Zentrum für Umweltforschung (UFZ) zeigt auf seiner

Website neben den SMI Indices auch Informationen über die tagesaktuelle Bodenfeuchte in Prozent der nutzbaren Feldkapazität an, jedoch waren diese Informationen zum Zeitpunkt der Studie nicht zum Herunterladen verfügbar. Zusätzlich wären Informationen über biologische Stressoren wie Insekten und Pilze von Nutzen, da diese besonders im Süden von Deutschland einen erheblichen Einfluss auf die Waldgesundheit haben. Falls diese zusätzlichen Informationen über absolute Bodenfeuchte oder biologische Stressoren nicht flächendeckend für Deutschland verfügbar sind, könnte eine exemplarische Studie für ein kleineres Untersuchungsgebiet durchgeführt werden.

Literaturverzeichnis

- Adams, H.D., Luce, C.H., Breshears, D.D., Allen, C.D., Weiler, M., Hale, V.C., Smith, A.M.S., Huxman, T.E., 2012. Ecohydrological consequences of drought- and infestation- triggered tree die-off: insights and hypotheses. *Ecohydrol.* 5 (2), 145–159.
- Adams, H.D., Zeppel, M.J.B., Anderegg, W.R.L., Hartmann, H., Landhäusser, S.M., Tissue, D.T., Huxman, T.E., Hudson, P.J., Franz, T.E., Allen, C.D., Anderegg, L.D.L., Barron-Gafford, G.A., Beerling, D.J., Breshears, D.D., Brodribb, T.J., Bugmann, H., Cobb, R.C., Collins, A.D., Dickman, L.T., Duan, H., Ewers, B.E., Galiano, L., Galvez, D.A., Garcia-Forner, N., Gaylord, M.L., Germino, M.J., Gessler, A., Hacke, U.G., Hakamada, R., Hector, A., Jenkins, M.W., Kane, J.M., Kolb, T.E., Law, D.J., Lewis, J.D., Limousin, J.-M., Love, D.M., Macalady, A.K., Martínez-Vilalta, J., Mencuccini, M., Mitchell, P.J., Muss, J.D., O'Brien, M.J., O'Grady, A.P., Pangle, R.E., Pinkard, E.A., Piper, F.I., Plaut, J.A., Pockman, W.T., Quirk, J., Reinhardt, K., Ripullone, F., Ryan, M.G., Sala, A., Sevanto, S., Sperry, J.S., Vargas, R., Vennetier, M., Way, D.A., Xu, C., Yezpez, E.A., McDowell, N.G., 2017. A multi-species synthesis of physiological mechanisms in drought-induced tree mortality. *Nature Ecology & Evolution* 1 (9), 1285–1291. <https://doi.org/10.1038/s41559-017-0248-x>.
- Allen, C.D., Macalady, A.K., Chenchouni, H., Bachelet, D., McDowell, N., Vennetier, M., Kitzberger, T., Rigling, A., Breshears, D.D., Hogg, E.H., Gonzalez, P., Fensham, R., Zhang, Z., Castro, J., Demidova, N., Lim, J.-H., Allard, G., Running, S.W., Semerci, A., Cobb, N., 2010. A global overview of drought and heat-induced tree mortality reveals emerging climate change risks for forests. *Forest Ecology and Management* 259 (4), 660–684.
- Anderegg, W.R.L., Berry, J.A., Smith, D.D., Sperry, J.S., Anderegg, L.D.L., Field, C.B., 2012. The roles of hydraulic and carbon stress in a widespread climate-induced forest die-off. *Proceedings of the National Academy of Sciences of the United States of America* 109 (1), 233–237.
- Anderegg, W.R.L., Hicke, J.A., Fisher, R.A., Allen, C.D., Aukema, J., Bentz, B., Hood, S., Lichstein, J.W., Macalady, A.K., McDowell, N., Pan, Y., Raffa, K., Sala, A., Shaw, J.D., Stephenson, N.L., Tague, C., Zeppel, M., 2015. Tree mortality from drought, insects, and their interactions in a changing climate. *The New phytologist* 208 (3), 674–683.
- Anderegg, W.R.L., Kane, J.M., Anderegg, L.D.L., 2013. Consequences of widespread tree mortality triggered by drought and temperature stress. *Nature Clim Change* 3 (1), 30–36.
- Bachmair, S., Kohn, I., Stahl, K., 2015. Exploring the link between drought indicators and impacts. *Nat. Hazards Earth Syst. Sci.* 15 (6), 1381–1397.
- Bachmair, S., Stahl, K., Collins, K., Hannaford, J., Acreman, M., Svoboda, M., Knutson, C., Smith, K.H., Wall, N., Fuchs, B., Crossman, N.D., Overton, I.C., 2016a. Drought indicators revisited: the need for a wider consideration of environment and society. *WIREs Water* 3 (4), 516–536.

- Bachmair, S., Svensson, C., Hannaford, J., Barker, L.J., Stahl, K., 2016b. A quantitative analysis to objectively appraise drought indicators and model drought impacts. *Hydrol. Earth Syst. Sci.* 20 (7), 2589–2609.
- Bachmair, S., Svensson, C., Prosdocimi, I., Hannaford, J., Stahl, K., 2017. Developing drought impact functions for drought risk management. *Nat. Hazards Earth Syst. Sci.* 17 (11), 1947–1960.
- Bachmair, S., Tanguy, M., Hannaford, J., Stahl, K., 2018. How well do meteorological indicators represent agricultural and forest drought across Europe? *Environ. Res. Lett.* 13 (3), 34042.
- Barton, K., 2019. MuMIn: Multi-model interference. R-Package Version 1.43.6 <https://CRAN.R-project.org/package=MuMIn>.
- Bates, D., Mächler, M., Bolker, B., Walker, S., 2015. Fitting Linear Mixed-Effects Models Using lme4. *J. Stat. Soft.* 67 (1).
- Beguería, S., Vicente-Serrano, S.M., Angulo-Martínez, M., 2010. A Multiscalar Global Drought Dataset: The SPEIbase: A New Gridded Product for the Analysis of Drought Variability and Impacts. *Bull. Amer. Meteor. Soc.* 91 (10), 1351–1356.
- Beguería, S., Vicente-Serrano, S.M., Beguería, M.S., 2017. SPEI: Calculation of the Standardised Precipitation-Evaporation Index. R package version 1.7. <https://CRAN.R-project.org/package=SPEI>.
- Beguería, S., Vicente-Serrano, S.M., Reig, F., Latorre, B., 2014. Standardized precipitation evapotranspiration index (SPEI) revisited: parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. *Int. J. Climatol.* 34 (10), 3001–3023.
- Blauhut, V., Gudmundsson, L., Stahl, K., 2015. Towards pan-European drought risk maps: quantifying the link between drought indices and reported drought impacts. *Environ. Res. Lett.* 10 (1), 14008.
- Blauhut, V., Stahl, K., Stagge, J.H., Tallaksen, L.M., Stefano, L. de, Vogt, J., 2016. Estimating drought risk across Europe from reported drought impacts, drought indices, and vulnerability factors. *Hydrol. Earth Syst. Sci.* 20 (7), 2779–2800.
- BMLE, 2017. Waldbericht der Bundesregierung 2017. Bundesministerium für Landwirtschaft und Ernährung.
- Bohn, U., Gollub, G., 2007. Buchenwälder als natürliche Vegetation in Europa. Beech forests as natural vegetation in Europe. *Natur und Landschaft* 20 (8), 391–397.
- Boisvenue, C., Running, S.W., 2006. Impacts of climate change on natural forest productivity - evidence since the middle of the 20th century. *Global Change Biol* 12 (5), 862–882.
- Brasseur, G.P., Jacob, D., Schuck-Zöller, S., 2017. Klimawandel in Deutschland: Entwicklung, Folgen, Risiken und Perspektiven. Springer.
- Bréda, N., Huc, R., Granier, A., Dreyer, E., 2006. Temperate forest trees and stands under severe drought: a review of ecophysiological responses, adaptation processes and long-term consequences. *Ann. For. Sci.* 63 (6), 625–644.
- Breslow, N.E., Clayton, D.G., 1993. Approximate Inference in Generalized Linear Mixed Models. *Journal of the American Statistical Association* 88 (421), 9–25.

- C3S, 2019. E-OBS data access chunks. E-OBS dataset from the EU-FP6 project UERRA. Copernicus Climate Change Service. http://surfobs.climate.copernicus.eu/dataaccess/access_eobs_chunks.php. Accessed December 3, 2019.
- Caldeira, M.C., 2019. The timing of drought coupled with pathogens may boost tree mortality. *Tree physiology* 39 (1), 1–5.
- Camarero, J.J., Gazol, A., Sangüesa-Barreda, G., Oliva, J., Vicente-Serrano, S.M., 2015. To die or not to die: early warnings of tree dieback in response to a severe drought. *J Ecol* 103 (1), 44–57.
- Christensen, J.H., Hewitson, B., Busuioac, A., Chen, A., Gao, X., Held, R., Jones, R., Kolli, R.K., Kwon, W.K., Laprise, R., Magana Rueda, V., Mearns, L., Menendez, C.G., Räisänen, J., Rinke, A., Sarr, A., Whetton, P., Arritt, R., Benestad, R., Beniston, M., Bromwich, D., Caya, D., Comiso, J., Elia, R. de, Dethloff, K., 2007. *Climate change 2007. The physical science basis ; contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. Cambridge University Press, New York.
- Ciais, P., Reichstein, M., Viovy, N., Granier, A., Ogée, J., Allard, V., Aubinet, M., Buchmann, N., Bernhofer, C., Carrara, A., Chevallier, F., Noblet, N. de, Friend, A.D., Friedlingstein, P., Grünwald, T., Heinesch, B., Keronen, P., Knohl, A., Krinner, G., Loustau, D., Manca, G., Matteucci, G., Miglietta, F., Ourcival, J.M., Papale, D., Pilegaard, K., Rambal, S., Seufert, G., Soussana, J.F., Sanz, M.J., Schulze, E.D., Vesala, T., Valentini, R., 2005. Europe-wide reduction in primary productivity caused by the heat and drought in 2003. *Nature* 437 (7058), 529–533.
- Cochard, H., 1992. Vulnerability of several conifers to air embolism. *Tree physiology* 11 (1), 73–83.
- Cook, R.D., Weisberg, S., 1995. *Residuals and influence in regression*. Chapman et Hall, London.
- Cornes, R.C., van der Schrier, G., van den Besselaar, E.J.M., Jones, P.D., 2018. An Ensemble Version of the E-OBS Temperature and Precipitation Data Sets. *J. Geophys. Res. Atmos.* 123 (17), 9391–9409. <https://www.ecad.eu/download/ensembles/download.php>.
- Crawley, M.J., 2002. *Statistical computing an introduction to data analysis using S-Plus*. UK: Wiley, Chichester.
- Deutschländer, T., Dalelane, C., 2012. *Auswertung regionaler Klimaprojektionen für Deutschland hinsichtlich der Änderung des Extremverhaltens von Temperatur, Niederschlag und Windgeschwindigkeit: ein Forschungsvorhaben der ressortübergreifenden Behördenallianz Bundesamt für Bevölkerungsschutz und Katastrophenhilfe, Bundesanstalt Technisches Hilfswerk, Deutscher Wetterdienst, Umweltbundesamt; Abschlussbericht*. DWD, Offenbach am Main.
- Dormann, C.F., 2013. *Parametrische Statistik. Verteilungen, maximum likelihood and GLM in R*. Springer, Berlin, Heidelberg.
- Dormann, C.F., Elith, J., Bacher, S., Buchmann, C., Carl, G., Carré, G., Marquéz, J.R.G., Gruber, B., Lafourcade, B., Leitão, P.J., Münkemüller, T., McClean, C., Osborne, P.E., Reineking, B., Schröder, B., Skidmore, A.K., Zurell, D., Lautenbach, S., 2013. Collinearity: a review of methods to deal with it and a simulation study evaluating their performance. *Ecography* 36 (1), 27–46.

- Dörrbecker, M.(C.), 2019. Deutschland NUTS-Ebenen 1 und 2. Eigenes Werk, CC BY-SA 2.5. <https://commons.wikimedia.org/w/index.php?curid=6779016>. Accessed December 3, 2019.
- DWD, 2019. Zahlen und Fakten zum Klimawandel in Deutschland. Anhang zur DWD-Presskonferenz am 26. März 2019 in Berlin. Deutscher Wetterdienst.
- EDC, 2013. Welcome to the EDII and EDR database. European Drought Centre. <http://www.geo.uio.no/edc/droughtdb/index.php>. Accessed December 3, 2019.
- EDC, 2015. DROUGHT R&SPI. European Drought Centre. <http://www.eu-drought.org/>. Accessed December 3, 2019.
- Eichhorn, J., Roskams, P., Potočić, N., Timmermann, V., Ferretti, M., Mues, V., Szepesi, A., Durrant, D., Seletković, I., Schröck, H.-W., Nevalainen, S., Bussotti, F., Garcia, P., Wulff, S., 2017. Part IV: Visual Assessment of Crown Condition and Damaging Agents. In: UNECE ICP Forests Programme Co-ordinating Centre (Editor), Manual on methods and criteria for harmonized sampling, assessment, monitoring and analysis of the effects of air pollution on forests, Eberswalde.
- Eickenscheidt, N., Augustin, N.H., Wellbrock, N., 2019. Spatio-temporal modelling of forest monitoring data: Modelling German tree defoliation data collected between 1989 and 2015 for trend estimation and survey grid examination using GAMMs. *iForest* 12, 338–348. <http://arxiv.org/pdf/1805.09216v1>.
- Eickenscheidt, N., Wellbrock, N., 2014. Consistency of defoliation data of the national training courses for the forest condition survey in Germany from 1992 to 2012. *Environmental Monitoring and Assessment* 186 (1), 257–275. <https://doi.org/10.1007/s10661-013-3372-3>.
- Europäische Kommission, 2015. Regions in the European Union. Nomenclature of territorial units for statistics ; NUTS 2013/EU-28. Publ. of the Europ. Union, Luxembourg.
- Europäische Kommission, 2019. NUTS - Systematik der Gbiertseinheit für die Statistik. Hintergrund. <https://ec.europa.eu/eurostat/de/web/nuts/background>. Accessed.
- Ferretti, M., Fischer, R., Mues, V., Granke, O., Lorenz, M., Seidling, W., 2017. Part II: Basic design principles for the ICP Forests Monitoring Networks. In: UNECE ICP Forests Programme Co-ordinating Centre (Editor), Manual on methods and criteria for harmonized sampling, assessment, monitoring and analysis of the effects of air pollution on forests, Eberswalde.
- Forner, A., Valladares, F., Bonal, D., Granier, A., Grossiord, C., Aranda, I., 2018. Extreme droughts affecting Mediterranean tree species' growth and water-use efficiency: the importance of timing. *Tree physiology* 38 (8), 1127–1137.
- Fu, X., Svoboda, M., Tang, Z., Dai, Z., Wu, J., 2013. An overview of US state drought plans: crisis or risk management? *Nat Hazards* 69 (3), 1607–1627.
- Gauster, T., Stagge, J.H., 2019. jstagge/hydroDrought:. Version 0.1 Pre-release. Zenodo. doi: 10.5281/zenodo.3561064. Accessed December 4, 2019.
- Gelman, A., Hill, J., 2007. Data analysis using regression and multilevel/hierarchical models. Cambridge University Press, Cambridge, New York.

- González Tánago, I., Urquijo, J., Blauhut, V., Villarroja, F., Stefano, L. de, 2016. Learning from experience: a systematic review of assessments of vulnerability to drought. *Nat Hazards* 80 (2), 951–973.
- Gößwein, S., lemme, H., Petercord, R., 2017. Prachtkäfer profitieren vom Trockensommer 2015. Bayerische Landesanstalt für Wald- und Forstwirtschaft. LWF aktuell 112 (1), 14–17.
- Gudmundsson, L., Rego, F.C., Rocha, M., Seneviratne, S.I., 2014. Predicting above normal wildfire activity in southern Europe as a function of meteorological drought. *Environ. Res. Lett.* 9 (8), 84008.
- Gudmundsson, L., Stagle, J.H., 2016. *SCI: Standardized Climate Indices such as SPI, SRI or SPEI. R package version 1.0-2.*
- Harrison, X.A., Donaldson, L., Correa-Cano, M.E., Evans, J., Fisher, D.N., Goodwin, C.E.D., Robinson, B.S., Hodgson, D.J., Inger, R., 2018. A brief introduction to mixed effects modelling and multi-model inference in ecology. *PeerJ* 6, e4794.
- Hartmann, D.L., Klein Tank A.M.G., Rusticucci, M., Alexander, L.V., Brönnimann, S., Charabi, Y., Dentener, F.J., Dlugokencky, E.J., Easterling, D.R., Kaplan, A., Soden, B.J., Thorne, P.W., Wild, M., Zhai, P.M., 2013. Observations: Atmosphere and Surface. In: IPCC (Editor), *Climate Change 2013: The Physical Science Basis. Contribution of Working Group I to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*, Cambridge, United Kingdom and New York, NY, USA.
- Hayes, M., Svoboda, M., Wall, N., Widhalm, M., 2011. The Lincoln Declaration on Drought Indices: Universal Meteorological Drought Index Recommended. *Bull. Amer. Meteor. Soc.* 92 (4), 485–488.
- Heim, R.R., 2002. A Review of Twentieth-Century Drought Indices Used in the United States. *Bulletin of the American Meteorological Society* 83 (8), 1149–1166.
- Hoy, A., Hänsel, S., Skalak, P., Ustrnul, Z., Bochníček, O., 2017. The extreme European summer of 2015 in a long-term perspective. *Int. J. Climatol.* 37 (2), 943–962.
- Iacopetti, G., Bussotti, F., Selvi, F., Maggino, F., Pollastrini, M., 2019. Forest ecological heterogeneity determines contrasting relationships between crown defoliation and tree diversity. *Forest Ecology and Management* 448, 321–329.
- ICP Forest, 2016. *ICP Forest Manual. International Co-operative Programme on Assessment and Monitoring of Air Pollution Effects on Forests.* <http://icp-forests.net/page/icp-forests-manual>. Accessed December 3, 2019.
- IPCC, 2012. *Managing the Risks of Extreme Events and Disasters to Advance Climate Change Adaptation. A Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change.* Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.
- IPCC, 2014. *Climate Change 2014: Impacts, Adaptation, and Vulnerability. Part B: Regional Aspects. Contribution of Working Group II to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change.* Cambridge University Press, Cambridge, United Kingdom and New York, NY, USA.

- Jacob, D., Petersen, J., Eggert, B., Alias, A., Christensen, O.B., Bouwer, L.M., Braun, A., Colette, A., Déqué, M., Georgievski, G., Georgopoulou, E., Gobiet, A., Menut, L., Nikulin, G., Haensler, A., Hempelmann, N., Jones, C., Keuler, K., Kovats, S., Kröner, N., Kotlarski, S., Kriegsmann, A., Martin, E., van Meijgaard, E., Moseley, C., Pfeifer, S., Preuschmann, S., Radermacher, C., Radtke, K., Rechid, D., Rounsevell, M., Samuelsson, P., Somot, S., Soussana, J.-F., Teichmann, C., Valentini, R., Vautard, R., Weber, B., Yiou, P., 2014. EURO-CORDEX: new high-resolution climate change projections for European impact research. *Reg Environ Change* 14 (2), 563–578.
- Kallis, G., 2008. Droughts. *Annu. Rev. Environ. Resour.* 33 (1), 85–118.
- Klap, J.M., Oude Voshaar, J.H., Vries, W. de, Erisman, J.W., 2000. Effects of Environmental Stress on Forest Crown Condition in Europe. Part IV: Statistical Analysis of Relationships. *Water, Air, and Soil Pollution* 119 (1), 387–420.
- Knutson, C., Hayes, M., Phillips, T., 1998. How to reduce drought risk. Western Drought Coordination Council, Preparedness and Mitigation Working Group, Lincoln.
- Kölling, C., Zimmermann, L., 2007. Die Anfälligkeit der Wälder Deutschlands gegenüber dem Klimawandel. *Gefahrstoffe - Reinhaltung der Luft* 67 (6), 259–268.
- Lackstrom, K., Brennan, A., Ferguson, D., Crimmins, M., Darby, L., Dow, K., Ingram, K., Meadow, A., Reges, H., Shafer, M., Helm Smith, K. (Eds.), 2013. The Missing Piece: Drought Impacts Monitoring Report from a Workshop in Tucson, AZ MARCH 5-6, 2013.
- Leuschner, C., Backes, K., Hertel, D., Schipka, F., Schmitt, U., Terborg, O., Runge, M., 2001. Drought responses at leaf, stem and fine root levels of competitive *Fagus sylvatica* L. and *Quercus petraea* (Matt.) Liebl. trees in dry and wet years. *Forest Ecology and Management* 149 (1-3), 33–46.
- Lloyd-Hughes, B., 2014. The impracticality of a universal drought definition. *Theor Appl Climatol* 117 (3-4), 607–611.
- Lloyd-Hughes, B., Saunders, M.A., 2002. A drought climatology for Europe. *Int. J. Climatol.* 22 (13), 1571–1592.
- Marx, A., Samaniego, L., Kumar, R., Thober, S., Mai, J., Zink, M., 2016. Der Dürremonitor. Aktuelle Informationen zur Bodenfeuchte in Deutschland. *Forum für Hydrologie und Wasserbewirtschaftung* 37 (16).
- Mason, S.J., Graham, N.E., 2002. Areas beneath the relative operating characteristics (ROC) and relative operating levels (ROL) curves: Statistical significance and interpretation. *Q. J. R. Meteorol. Soc.* 128 (584), 2145–2166.
- McDowell, N., Pockman, W.T., Allen, C.D., Breshears, D.D., Cobb, N., Kolb, T., Plaut, J., Sperry, J., West, A., Williams, D.G., Yezpez, E.A., 2008. Mechanisms of plant survival and mortality during drought: why do some plants survive while others succumb to drought? *New Phytol* 178 (4), 719–739.

- McDowell, N.G., Beerling, D.J., Breshears, D.D., Fisher, R.A., Raffa, K.F., Stitt, M., 2011. The interdependence of mechanisms underlying climate-driven vegetation mortality. *Trends in ecology & evolution* 26 (10), 523–532.
- McFadden, D., 1974. Conditional Logit Analysis of Qualitative Choice Behavior. In: P. Zarembka (Editor), *Frontiers in Econometrics*. Academic Press New York, pp. 105–142.
- McKee, T.B., Doesken, N.J., Kleist, J. (Eds.), 1993. The relationship of drought frequency and duration to time scales. American Meteorological Society, Boston, MA, USA.
- Meehl, G.A., Tebaldi, C., 2004. More intense, more frequent, and longer lasting heat waves in the 21st century. *Science* (New York, N.Y.) 305 (5686), 994–997.
- Meinert, T., Bescker, A., Bissolli, P., Daßler, J., Breidenbach, J.N., Ziese, M., 2019. Ursachen und Folgen der Trockenheit in Deutschland und Europa ab Juni 2019. Deutscher Wetterdienst.
- Menard, S., 2000. Coefficients of Determination for Multiple Logistic Regression Analysis. *The American Statistician* 54 (1), 17–24.
- Michel, A., Seidling, W., 2016. Forest Condition in Europe. 2016 technical report of ICP forests ; report under the UNECE Convention on Long-Range Transboundary Air Pollution (CLRTAP). Johann Heinrich von Thünen-Institut, Eberswalde, Hamburg.
- Mishra, A.K., Singh, V.P., 2010. A review of drought concepts. *Journal of Hydrology* 391 (1-2), 202–216.
- Moosbrugger, H., Kelava, A., 2012. Testtheorie und Fragebogenkonstruktion. Springer-Verlag Berlin Heidelberg, Berlin, Heidelberg.
- Muukkonen, P., Nevalainen, S., Lindgren, M., Peltoniemi, M., 2015. Spatial occurrence of drought-associated damages in Finnish boreal forests: results from forest condition monitoring and GIS analysis. *Boreal Environment Research* 20 (2), 172–180. <https://jukuri.luke.fi/bitstream/handle/10024/485900/Muukkonen.pdf?sequence=1&isAllowed=y>.
- Obasi, G.O.P., 1994. WMO's role in the international decade for natural disaster reduction. *Bulletin of the American Meteorological Society* 75 (9), 1655–1662.
- Pohlert, T., 2018. trend: Non-Parametric Trend Tests and Change-Point Detection. R package version 1.1.1. <https://CRAN.R-project.org/package=trend>.
- Pretzsch, H., del Río, M., Ammer, C., Avdagic, A., Barbeito, I., Bielak, K., Brazaitis, G., Coll, L., Dirnberger, G., Drössler, L., Fabrika, M., Forrester, D.I., Godvod, K., Heym, M., Hurt, V., Kurylyak, V., Löf, M., Lombardi, F., Matović, B., Mohren, F., Motta, R., den Ouden, J., Pach, M., Ponette, Q., Schütze, G., Schweig, J., Skrzyszewski, J., Sramek, V., Sterba, H., Stojanović, D., Svoboda, M., Vanhellefont, M., Verheyen, K., Wellhausen, K., Zlatanov, T., Bravo-Oviedo, A., 2015. Growth and yield of mixed versus pure stands of Scots pine (*Pinus sylvestris* L.) and European beech (*Fagus sylvatica* L.) analysed along a productivity gradient through Europe. *Eur J Forest Res* 134 (5), 927–947.

- QGIS Entwicklungsteam, 2019. QGIS Geographisches Informationssystem. Version 3.4.13. Open Source Geospatial Foundation Projekt, <http://qgis.osgeo.org>.
- R Core Team, 2018. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria, <https://www.R-project.org/>.
- Raffa, K.F., Aukema, B.H., Bentz, B.J., Carroll, A.L., Hicke, J.A., Turner, M.G., Romme, W.H., 2008. Cross-scale Drivers of Natural Disturbances Prone to Anthropogenic Amplification: The Dynamics of Bark Beetle Eruptions. *BioScience* 58 (6), 501–517.
- Robin, X., Turck, N., Hainard, A., Tiberti, N., Lisacek, F., Sanchez, J.-C., Müller, M., 2011. pROC: an open-source package for R and S+ to analyze and compare ROC curves. *BMC Bioinformatics* 12 (1), 77. <https://doi.org/10.1186/1471-2105-12-77>.
- Rosengren, U., Göransson, H., Jönsson, U., Stjernquist, I., Thelin, G., Wallander, H., 2006. Functional Biodiversity Aspects on the Nutrient Sustainability in Forests-Importance of Root Distribution. *Journal of Sustainable Forestry* 21 (2-3), 77–100.
- Rouault, G., Candau, J.-N., Lieutier, F., Nageleisen, L.-M., Martin, J.-C., Warzée, N., 2006. Effects of drought and heat on forest insect populations in relation to the 2003 drought in Western Europe. *Ann. For. Sci.* 63 (6), 613–624.
- RStudio Team, 2016. RStudio: Integrated Development for R. RStudio, Inc., Boston, MA, USA.
- Ryan, M.G., 2011. Tree responses to drought. *Tree physiology* 31 (3), 237–239.
- Samaniego, L., Kumar, R., Zink, M., 2013. Implications of Parameter Uncertainty on Soil Moisture Drought Analysis in Germany. *J. Hydrometeor* 14 (1), 47–68.
- Seidling, W., 2007. Signals of summer drought in crown condition data from the German Level I network. *Eur J Forest Res* 126 (4), 529–544.
- Seidling, W., Hansen, K., Strich, S., Lorenz, M., 2017. Part I: Objectives, Strategy and Implementation of ICP Forests. In: UNECE ICP Forests Programme Co-ordinating Centre (Editor), *Manual on methods and criteria for harmonized sampling, assessment, monitoring and analysis of the effects of air pollution on forests*, Eberswalde.
- Seidling, W., Mues, V., 2005. Statistical and geostatistical modelling of preliminarily adjusted defoliation on an European scale. *Environmental Monitoring and Assessment* 101 (1-3), 223–247.
- Sousa-Silva, R., Verheyen, K., Ponette, Q., Bay, E., Sioen, G., Titeux, H., van de Peer, T., van Meerbeek, K., Muys, B., 2018. Tree diversity mitigates defoliation after a drought-induced tipping point. *Global change biology* 24 (9), 4304–4315.
- Spinoni, J., Naumann, G., Vogt, J., Barbosa, P., 2016. Meteorological droughts in Europe. Events and impacts : past trends and future projections. Publications Office of the European Union, Luxembourg.
- Stagge, J.H., Kohn, I., Tallaksen, L.M., Stahl, K., 2015. Modeling drought impact occurrence based on meteorological drought indices in Europe. *Journal of Hydrology* 530, 37–50.
- Stahl, K., 2001. Hydrological Drought. A Study across Europe. Dissertation, Albert-Ludwigs-Universität, Freiburg i. Br.

- Stahl, K., Blauhut, V., Kohn, I., Acácio, V., Assimacopoulos, D., Bifulco, C., Stefano, L. de, Dias, S., Eilertz, D., Freilingsdorf, B., Hegdahl, T.J., Kampragou, E., Kourentzis, E., Melsen, L., van Lanen, H.A.J., van Loon, A.F., Massarutto, A., Musolino, D., Paoli, L. de, Senn, L., Stagge, J.H., Tallaksen, L.M., Urquijo, J., 2012. A European drought impact report inventory (EDII): Design and test for selected recent droughts in Europe. Wageningen Universiteit, Wageningen.
- Stahl, K., Kohn, I., Blauhut, V., Urquijo, J., De Stefano, L., Acácio, V., Dias, S., Stagge, J.H., Tallaksen, L.M., Kampragou, E., van Loon, A.F., Barker, L.J., Melsen, L.A., Bifulco, C., Musolino, D., de Carli, A., Massarutto, A., Assimacopoulos, D., van Lanen, H.A.J., 2016. Impacts of European drought events: insights from an international database of text-based reports. *Nat. Hazards Earth Syst. Sci.* 16 (3), 801–819.
- Statistisches Bundesamt, 2018. Forstwirtschaftliche Bodennutzung. Holzeinschlagsstatistik. Fachserie 3 Reihe 3.3.1.
- Sutmöller, J., Spellmann, H., Fiebinger, C., Albert, M., 2008. Der Klimawandel und seine Auswirkungen auf die Buchenwälder in Deutschland. In: Nordwestdeutsche Forstliche Versuchsanstalt (Editor), *Ergebnisse angewandter Forschung zur Buche*. Göttingen University Press, Göttingen, pp. 135–158.
- Taege, S., Zang, C., Liesebach, M., Schneck, V., Menzel, A., 2013. Impact of climate and drought events on the growth of Scots pine (*Pinus sylvestris* L.) provenances. *Forest Ecology and Management* 307, 30–42.
- Tannehill, I.R., 1947. Drought, its causes and effects. LWW, Princeton.
- Tardieu, F., Simonneau, T., 1998. Variability among species of stomatal control under fluctuating soil water status and evaporative demand: modelling isohydric and anisohydric behaviours. *Journal of Experimental Botany* 49 (Special Issue), 419–432.
- Trugman, A.T., Detto, M., Bartlett, M.K., Medvigy, D., Anderegg, W.R.L., Schwalm, C., Schaffer, B., Pacala, S.W., 2018. Tree carbon allocation explains forest drought-kill and recovery patterns. *Ecology letters* 21 (10), 1552–1560.
- UBA, 2006. Künftige Klimaänderungen in Deutschland - Regionale Projektionen für das 21. Jahrhundert. Hintergrundpapier. Umweltbundesamt.
- UBA, 2019a. CORINE Land Cover - CLC. Umweltbundesamt. <https://www.umweltbundesamt.de/themen/boden-landwirtschaft/flaechensparen-boeden-landschaften-erhalten/corine-land-cover-clc>. Accessed November 5, 2019.
- UBA, 2019b. GISU. Metadatenkatalog des Umweltbundesamtes. Umweltbundesamt. <https://gis.uba.de/catalog/OpenSearch.do?type=/Query/OpenSearch.do&search=CORINE>. Accessed December 3, 2019.
- UFZ, 2019. Dürremonitor Deutschland. Helmholtz Zentrum für Umweltforschung. <https://www.ufz.de/index.php?de=37937>. Accessed December 3, 2019.

- van Lanen, H.A.J., Peters, E., 2000. Definition, effects and assessment of groundwater droughts. In: J.V. Vogt, F. Somma (Editors), *Drought and drought mitigation in Europe*. Springer, Dordrecht, pp. 49–61.
- van Loon, A.F., Stahl, K., Di Baldassarre, G., Clark, J., Rangelcroft, S., Wanders, N., Gleeson, T., van Dijk, A.I.J.M., Tallaksen, L.M., Hannaford, J., Uijlenhoet, R., Teuling, A.J., Hannah, D.M., Sheffield, J., Svoboda, M., Verbeiren, B., Wagener, T., van Lanen, H.A.J., 2016. Drought in a human-modified world: reframing drought definitions, understanding, and analysis approaches. *Hydrol. Earth Syst. Sci.* 20 (9), 3631–3650.
- Vicente-Serrano, S.M., Beguería, S., López-Moreno, J.I., 2010. A Multiscalar Drought Index Sensitive to Global Warming: The Standardized Precipitation Evapotranspiration Index. *J. Climate* 23 (7), 1696–1718.
- Wei, T., Simko, V., 2017. R package "corrplot". Visualization of a correlation Matrix (Version 0.84). Available from <https://github.com/taiyun/corrplot>.
- Wilhite, D.A., 2000. Drought as a Natural Hazard: Concepts and Definitions. Chapter 1. *Drought: A Global Assessment (Volume I)*, 3–18.
- Wilhite, D.A., Glantz, M.H., 1985. Understanding: the Drought Phenomenon: The Role of Definitions. *Water International* 10 (3), 111–120.
- Wilhite, D.A., Svoboda, M.D., Hayes, M.J., 2007. Understanding the complex impacts of drought: A key to enhancing drought mitigation and preparedness. *Water Resour Manage* 21 (5), 763–774.
- Wilhite, D.A., Vanyarkho, O.V., 2000. Chapter 18 Drought: Pervasive Impacts of a Creeping Phenomenon. *Drought: A Global Assessment (Volume I)*, 245–255.
- Winter, B., 2013. Linear models and linear mixed effects models in R with linguistic applications.
- Zargar, A., Sadiq, R., Naser, B., Khan, F.I., 2011. A review of drought indices. *Environ. Rev.* 19 (NA), 333–349.
- Zink, M., Samaniego, L., Kumar, R., Thober, S., Mai, J., Schäfer, D., Marx, A., 2016. The German drought monitor. *Environ. Res. Lett.* 11 (7), 74002.
- Zuur, A.F., Smith, G.M., Saveliev, A.A., Walker, N., Ieno, E.N., 2009. *Mixed Effects Models and Extensions in Ecology with R*. Springer-Verlag, s.l.

Anhang

Abbildungen




Abbildung Anhang 1: Korrelationsmatrix aller Dürreindizes sowie des Beobachtungsjahres (Pearson's r)







Abbildung Anhang 2: NUTS-2-Regionen, in denen SMI 180, SMI 25, SPI 12 und SPI 6 signifikanter Prädiktor (logistische Regression, $p \leq 0.05$) für das Auftreten von Dürreauswirkungen waren (Grün).










Abbildung Anhang 3: NUTS-2-Regionen, in denen SPEI 3, SPEI 12, SPEI 24 und SPI 3 signifikanter Prädiktor (logistische Regression, $p \leq 0.05$) für das Auftreten von Dürreauswirkungen waren (Grün).




DE11 – SPEI 3



DE12 – SMI 180




DE13 – SPEI 3




DE14 – SPEI 3


Abbildung Anhang 4: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DE11, DE12, DE13, DE14




DE21 – SMI 180



DE22 – SPI 6




DE23 – SPEI 6




DE24 – SPEI 6


Abbildung Anhang 5: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DE21, DE22, DE23, DE24




DE25 – SPEI 6



DE26 – SPEI 6




DE27 – SPEI 3




DE40 – SPEI 24


Abbildung Anhang 6: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DE25, DE26, DE27, DE40




DE71 – SPEI 6



DE72 – SPI 12




DE73 – SMI 25




DEAI – SPEI 12

Abbildung Anhang 7: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DE71, DE72, DE72, DEAI



DEA2 – SPEI 6


DEA3 – SPEI 12




DEA5 – SPEI 12

DEB1 – SPEI 24


Abbildung Anhang 8: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DEA2, DEA3, DEA5, DEB1




DEB2 – SPEI 24



DEB3 – SPEI 24




DEC0 – SPEI 12



DED2 – SPEI 24

Abbildung Anhang 9: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DEB2, DEB3, DEC0, DED2



DED4 – SPEI24

DED5 – SPEI3

Abbildung Anhang 10: Zusammenhang zwischen den Indices mit der jeweils besten Modellgüte und der Wahrscheinlichkeit des Auftretens einer Auswirkung: DED4, DED5




Abbildung Anhang 11: ROC-Kurven für DE11









Abbildung Anhang 12: ROC-Kurven für DE12, DE13, DE14 und DE21









Abbildung Anhang 13: ROC-Kurven für DE22 und DE23




Abbildung Anhang 14: ROC-Kurven für DE24, DE25, DE26 und DE27




Abbildung Anhang 15: ROC-Kurven für DE40, DE71, DE72, DE73 und DEA1




Abbildung Anhang 16: ROC-Kurven DEA2, DEA3, DEA5, DEB1, DEB2 und DEB3








Abbildung Anhang 17: ROC-Kurven DEC0, DED2, DED4 und DED5




Abbildung Anhang 18: LMMs: Pearson Residuen gegen fixed effects für *Picea* (ICP Forest Daten)




Abbildung Anhang 19: LMMs: Pearson Residuen gegen fixed effects für Pinus (ICP Forest Daten)




Abbildung Anhang 20: LMMs Pearson Residuen gegen fixed effects für Quercus sp. (ICP Forest Daten)




Abbildung Anhang 21: Zusammenhang zwischen fixed effects und Kronenentlaubung für Fagus




Abbildung Anhang 22: Zusammenhang zwischen fixed effects und Kronenentlaubung für *Picea*




Abbildung Anhang 23: Zusammenhang zwischen fixed effects und Kronenentlaubung für Pinus




Abbildung Anhang 24: Zusammenhang zwischen fixed effects und Kronenentlaubung für *Quercus sp.*




Abbildung Anhang 25: Jährliches Schadholz durch Insekten je Bundesland von 2005 – 2018 (Daten des Statistischen Bundesamts).

Tabellen

Tabelle Anhang 1: Anzahl der Jahre mit mindestens einem EDII Eintrag pro Jahr und NUTS-2 Region

NUTS-2 Region	Anzahl der Jahre mit mindestens einer Auswirkung	NUTS-2 Region	Anzahl der Jahre mit mindestens einer Auswirkung
DEB2	8	DE71	5
DE12	7	DE72	5
DE13	7	DE91	4
DEB1	7	DEA1	4
DEB3	7	DEA2	4
DE11	6	DEA3	4
DE14	6	DEA4	4
DE21	6	DEA5	4
DE22	6	DE92	3
DE23	6	DE93	3
DE24	6	DE94	3
DE25	6	DEC0	3
DE26	6	DEE0	3
DE27	6	DEF0	3
DE73	6	DE30	2
DED2	6	DE80	2
DED4	6	DEG0	2
DED5	6	DE50	0
DE40	5	DE60	0

Tabelle Anhang 2: Zusammenfassende Statistiken für die Verteilung von Indices vs. Auswirkungen

Index	Auswirkung	Mittelwert	Median	SD	Anzahl
SPI 3	Alle	-0,124	-0,078	0,992	1672
SPI 3	Nein	-0,032	-0,027	0,93	1495
SPI 3	Ja	-0,898	-0,957	1,149	177
SPEI 3	Alle	-0,186	-0,238	0,992	1672
SPEI 3	Nein	-0,071	-0,184	0,942	1495
SPEI 3	Ja	-1,158	-1,402	0,874	177
SPI 6	Alle	-0,119	-0,09	0,987	1672
SPI 6	Nein	-0,013	-0,019	0,916	1495

SPI 6	Ja	-1,019	-0,945	1,103	177
SPEI 6	Alle	-0,206	-0,345	0,996	1672
SPEI 6	Nein	-0,08	-0,26	0,94	1495
SPEI 6	Ja	-1,275	-1,376	0,8	177
SPI 12	Alle	0,025	0,007	0,947	1672
SPI 12	Nein	0,126	0,09	0,901	1495
SPI 12	Ja	-0,828	-0,704	0,892	177
SPEI 12	Alle	-0,213	-0,382	0,992	1672
SPEI 12	Nein	-0,093	-0,294	0,949	1495
SPEI 12	Ja	-1,227	-1,375	0,741	177
SPI 24	Alle	0,046	0,042	0,929	1672
SPI 24	Nein	0,116	0,109	0,909	1495
SPI 24	Ja	-0,538	-0,468	0,895	177
SPEI 24	Alle	-0,238	-0,412	1,018	1672
SPEI 24	Nein	-0,118	-0,303	0,991	1495
SPEI 24	Ja	-1,252	-1,313	0,587	177
SMI 25	Alle	0,142	0,117	0,1	1672
SMI 25	Nein	0,149	0,125	0,1	1495
SMI 25	Ja	0,083	0,054	0,081	177
SMI 180	Alle	0,199	0,157	0,152	1672
SMI 180	Nein	0,212	0,171	0,152	1495
SMI 180	Ja	0,085	0,05	0,088	177

Tabelle Anhang 3: Durchschnittliche Anzahl der Bäume je NUTS-2 Region, an denen der Parameter Kronenentlaubung erhoben wurde sowie Ergebnisse des Mann-Kendall Trendtests: Zunahme (+), Abnahme (-) oder kein Trend (0).

NUTS ID	<i>Fagus</i>	Trend	<i>Picea</i>	Trend	<i>Pinus</i>	Trend	<i>Quercus sp.</i>	Trend
DE11	30	-	31	-	1	-	11	0
DE12	31	-	17	-	13	0	6	+
DE13	15	-	79	-	7	0	3	0
DE14	21	-	43	+	2	0	8	-
DE21	45	0	122	0	12	+	4	+
DE22	21	+	81	+	17	0	12	+
DE23	10	-	72	0	81	0	5	+
DE24	14	0	54	0	44	-	1	0
DE25	11	0	19	0	53	-	25	0
DE26	67	-	54	-	34	-	31	0

DE27	24	0	64	0	6	0	9	+
DE30	6	0	NA	0	11	0	12	0
DE40	7	-	3	0	234	+	25	-
DE71	29	-	19	-	25	0	29	0
DE72	16	0	12	0	8	+	2	0
DE73	48	0	16	0	20	+	16	0
DE80	2	0	17	+	49	0	10	0
DE91	14	0	33	0	5	0	8	0
DE92	13	0	5	0	15	0	1	0
DE93	NA	0	5	-	58	0	3	0
DE94	2	0	15	-	16	0	6	-
DEA1	10	0	NA	0	7	0	13	-
DEA2	9	-	9	-	NA	0	6	-
DEA3	1	0	NA	0	NA	0	11	0
DEA4	33	-	18	0	6	0	23	-
DEA5	56	-	46	-	1	0	15	0
DEB1	16	0	19	-	3	-	9	-
DEB2	15	0	12	0	6	-	19	0
DEB3	24	-	6	-	19	-	4	0
DEC0	8	-	6	0	9	0	5	0
DED2	2	-	22	+	47	0	6	0
DED4	1	0	18	-	2	0	1	0
DED5	NA	0	NA	0	6	0	7	0
DEE0	15	-	13	0	43	+	13	0
DEF0	8	0	25	0	9	0	3	+
DEG0	52	0	68	0	50	+	18	0
Gesamt	686		1023		919		382	

Tabelle Anhang 4: Jährlicher durch Insekten verursachter Holzeinschlag zwischen 2005 – 2018 je Bundesland

Jahr	Bundesland	Insgesamt	Eiche	Buche	Kiefer	Fichte
2005	Baden-Württemberg	2082,2	7,6	28,9	33,1	2012,6
2005	Bayern	704,7	0,3	0,6	4,1	699,6
2005	Berlin	0,4	0,0	–	0,4	–
2005	Brandenburg	17,1	1,1	0,1	6,0	9,9
2005	Hamburg	0,1	–	–	–	0,1
2005	Hessen	614,9	0,3	0,3	23,1	591,2

2005	Mecklenburg-Vorpommern	10,1	0,1	0,1	2,4	7,6
2005	Niedersachsen	129,3	2,6	0,8	5,4	120,5
2005	Nordrhein-Westfalen	106,2	1,4	3,2	1,0	100,7
2005	Rheinland-Pfalz	201,2	1,6	0,1	1,6	197,9
2005	Saarland	36,2	0,0	0,1	0,3	35,8
2005	Sachsen	12,4	0,1	0,1	1,2	11,1
2005	Sachsen-Anhalt	81,7	3,9	0,3	2,2	75,3
2005	Schleswig-Holstein	3,0	0,0	0,3	0,2	2,5
2005	Thüringen	114,1	0,8	0,8	2,5	110,1
2006	Baden-Württemberg	1854,8	5,9	24,7	23,2	1801,0
2006	Bayern	1222,1	0,1	1,5	5,3	1215,2
2006	Berlin	0,1	0,0	–	0,0	0,0
2006	Brandenburg	27,2	1,8	0,2	16,1	9,1
2006	Hamburg	0,0	–	–	–	0,0
2006	Hessen	668,8	0,5	0,1	18,9	649,2
2006	Mecklenburg-Vorpommern	6,5	0,1	0,1	1,8	4,5
2006	Niedersachsen	250,9	0,6	3,0	8,9	238,4
2006	Nordrhein-Westfalen	271,8	1,3	12,0	2,4	256,1
2006	Rheinland-Pfalz	321,4	1,4	0,1	1,3	318,5
2006	Saarland	34,3	0,1	0,0	0,4	33,9
2006	Sachsen	37,4	0,1	0,1	1,7	35,5
2006	Sachsen-Anhalt	90,5	4,5	1,3	6,6	78,1
2006	Schleswig-Holstein	38,0	0,1	0,0	0,3	37,5
2006	Thüringen	198,4	0,2	1,0	2,0	195,3
2007	Baden-Württemberg	815,1	7,0	18,4	19,1	770,6
2007	Bayern	866,6	1,0	0,7	5,3	859,7
2007	Berlin	0,0	–	–	0,0	–
2007	Brandenburg	21,0	1,6	0,2	13,0	6,2
2007	Hamburg	0,5	–	–	–	0,5
2007	Hessen	172,3	0,2	0,1	11,9	160,1
2007	Mecklenburg-Vorpommern	4,8	0,7	0,3	1,0	2,8
2007	Niedersachsen	95,5	0,9	1,0	6,2	87,5
2007	Nordrhein-Westfalen	54,8	0,4	0,2	1,2	53,0
2007	Rheinland-Pfalz	129,8	3,5	0,0	3,2	123,0
2007	Saarland	20,8	0,0	0,1	0,4	20,2
2007	Sachsen	23,0	0,1	0,3	1,8	20,8
2007	Sachsen-Anhalt	104,4	4,5	0,5	4,2	95,2

2007	Schleswig-Holstein	27,8	0,1	0,0	0,5	27,2
2007	Thüringen	160,6	0,2	1,3	3,1	155,9
2008	Baden-Württemberg	255,3	3,4	12,3	7,1	232,5
2008	Bayern	2384,4	19,4	17,2	67,3	2280,6
2008	Berlin	0,0	–	–	0,0	–
2008	Brandenburg	19,2	2,6	0,2	9,4	7,0
2008	Hamburg	0,0	–	–	–	0,0
2008	Hessen	640,1	0,2	0,0	7,2	632,6
2008	Mecklenburg-Vorpommern	1,0	0,3	0,0	0,1	0,6
2008	Niedersachsen	194,1	2,2	3,3	3,6	185,0
2008	Nordrhein-Westfalen	346,8	1,1	2,4	3,1	340,2
2008	Rheinland-Pfalz	116,9	1,5	0,5	1,6	113,2
2008	Saarland	10,6	0,0	0,1	0,1	10,3
2008	Sachsen	92,3	0,1	0,3	2,0	89,9
2008	Sachsen-Anhalt	117,5	7,6	1,5	3,3	105,1
2008	Schleswig-Holstein	6,1	0,1	0,1	0,0	6,0
2008	Thüringen	374,8	0,1	0,3	3,9	370,5
2009	Baden-Württemberg	157,4	1,3	7,0	5,1	143,9
2009	Bayern	1791,3	8,0	9,7	78,1	1695,5
2009	Berlin	0,0	–	–	0,0	–
2009	Brandenburg	13,7	0,7	1,4	6,8	4,9
2009	Hamburg	0,1	–	–	–	0,1
2009	Hessen	778,3	0,0	0,1	10,6	767,7
2009	Mecklenburg-Vorpommern	0,3	–	–	0,1	0,2
2009	Niedersachsen	136,5	2,6	1,4	4,5	128,0
2009	Nordrhein-Westfalen	648,8	1,9	3,2	4,0	639,8
2009	Rheinland-Pfalz	83,2	1,1	0,1	0,4	81,5
2009	Saarland	6,6	0,1	0,1	0,1	6,4
2009	Sachsen	35,5	0,1	0,2	1,2	34,0
2009	Sachsen-Anhalt	53,7	4,3	1,4	4,5	43,5
2009	Schleswig-Holstein	5,8	0,1	0,0	0,1	5,6
2009	Thüringen	181,2	0,0	0,6	1,6	179,0
2010	Baden-Württemberg	144,9	0,9	7,5	3,0	133,5
2010	Bayern	931,2	1,9	10,9	37,7	880,7
2010	Berlin	0,0	–	–	–	0,0
2010	Brandenburg	16,3	1,5	0,1	10,2	4,5
2010	Hamburg	0,1	–	–	–	0,1

2010	Hessen	92,0	0,0	0,1	5,6	86,3
2010	Mecklenburg-Vorpommern	0,7	0,1	0,0	0,1	0,5
2010	Niedersachsen	48,2	0,3	1,3	4,3	42,3
2010	Nordrhein-Westfalen	130,0	0,5	0,7	3,4	125,4
2010	Rheinland-Pfalz	22,6	0,2	0,0	0,2	22,1
2010	Saarland	0,1	–	–	0,1	0,0
2010	Sachsen	16,7	–	–	2,4	14,2
2010	Sachsen-Anhalt	38,1	3,3	1,7	21,4	11,8
2010	Schleswig-Holstein	3,1	0,0	0,0	0,2	2,9
2010	Thüringen	43,6	0,1	1,1	2,7	39,7
2011	Baden-Württemberg	131,8	7,0	13,0	4,6	107,2
2011	Bayern	357,5	9,0	1,9	8,9	337,6
2011	Berlin	–	–	–	–	–
2011	Brandenburg	8,3	1,4	0,2	4,3	2,3
2011	Hamburg	0,0	–	–	–	0,0
2011	Hessen	226,6	0,0	0,0	4,9	221,5
2011	Mecklenburg-Vorpommern	0,9	0,0	0,0	0,1	0,8
2011	Niedersachsen	41,6	4,9	1,0	4,1	31,6
2011	Nordrhein-Westfalen	94,5	1,8	0,8	1,9	90,0
2011	Rheinland-Pfalz	238,3	1,9	0,0	1,2	235,2
2011	Saarland	27,8	–	0,0	0,6	27,2
2011	Sachsen	13,0	0,0	0,1	5,1	7,7
2011	Sachsen-Anhalt	21,8	2,1	1,8	6,9	10,9
2011	Schleswig-Holstein	5,0	0,0	–	–	5,0
2011	Thüringen	27,0	0,1	0,4	2,2	24,3
2012	Baden-Württemberg	67,5	4,5	6,4	3,7	52,8
2012	Bayern	320,9	5,4	1,7	5,7	308,1
2012	Berlin	–	–	–	–	–
2012	Brandenburg	19,3	0,8	0,9	12,3	5,3
2012	Hamburg	–	–	–	–	–
2012	Hessen	137,5	0,1	0,0	4,6	132,8
2012	Mecklenburg-Vorpommern	4,6	0,4	1,1	0,9	2,2
2012	Niedersachsen	36,9	10,0	0,9	2,0	24,0
2012	Nordrhein-Westfalen	75,4	5,7	0,7	2,1	66,9
2012	Rheinland-Pfalz	106,1	1,3	0,0	0,7	104,0
2012	Saarland	22,2	0,1	0,1	0,3	21,7
2012	Sachsen	9,9	0,2	0,2	2,8	6,7

2012	Sachsen-Anhalt	17,1	4,0	1,5	5,9	5,8
2012	Schleswig-Holstein	4,6	0,2	0,3	0,2	3,9
2012	Thüringen	47,7	0,7	0,2	1,7	45,1
2013	Baden-Württemberg	311,6	3,7	18,3	6,3	283,3
2013	Bayern	822,2	13,5	0,6	10,9	797,1
2013	Berlin	–	–	–	–	–
2013	Brandenburg	10,1	0,9	0,2	6,1	2,8
2013	Hamburg	0,1	–	–	–	0,1
2013	Hessen	152,3	0,3	–	4,2	147,7
2013	Mecklenburg-Vorpommern	13,2	0,3	2,6	2,0	8,3
2013	Niedersachsen	59,2	8,3	1,1	1,9	47,8
2013	Nordrhein-Westfalen	98,6	5,2	0,5	2,7	90,1
2013	Rheinland-Pfalz	65,4	0,8	–	0,4	64,2
2013	Saarland	15,2	0,2	0,1	0,2	14,7
2013	Sachsen	14,1	0,1	0,0	1,6	12,3
2013	Sachsen-Anhalt	21,3	2,1	0,4	5,0	13,7
2013	Schleswig-Holstein	3,8	1,2	0,2	0,1	2,3
2013	Thüringen	117,0	0,4	0,3	1,8	114,5
2014	Baden-Württemberg	307,0	3,3	23,6	9,5	270,6
2014	Bayern	896,8	6,3	2,8	13,5	874,2
2014	Berlin	–	–	–	–	–
2014	Brandenburg	16,4	1,7	1,1	8,8	4,7
2014	Hamburg	0,1	–	–	–	0,1
2014	Hessen	120,1	0,1	–	5,1	114,9
2014	Mecklenburg-Vorpommern	10,1	0,4	3,2	1,0	5,5
2014	Niedersachsen	81,7	9,2	0,8	7,8	64,0
2014	Nordrhein-Westfalen	80,6	4,7	0,5	1,4	74,0
2014	Rheinland-Pfalz	41,7	0,2	–	0,6	40,9
2014	Saarland	9,6	–	–	0,1	9,4
2014	Sachsen	41,2	–	0,1	1,3	39,8
2014	Sachsen-Anhalt	26,0	2,7	0,7	2,9	19,7
2014	Schleswig-Holstein	6,7	0,4	0,1	0,1	6,2
2014	Thüringen	114,4	0,3	0,7	1,8	111,6
2015	Baden-Württemberg	452,3	2,0	22,7	10,3	417,3
2015	Bayern	2504,0	4,3	0,4	72,5	2426,8
2015	Berlin	–	–	–	–	–
2015	Brandenburg	22,2	3,2	0,3	10,1	8,7

2015	Hamburg	–	–	–	–	–
2015	Hessen	101,8	0,2	0,1	4,5	96,9
2015	Mecklenburg-Vorpommern	8,0	2,8	0,5	1,0	3,7
2015	Niedersachsen	40,1	5,5	1,2	4,5	29,0
2015	Nordrhein-Westfalen	35,5	5,1	0,3	0,9	29,3
2015	Rheinland-Pfalz	36,9	0,3	0,0	0,6	36,0
2015	Saarland	18,3	0,5	0,3	1,1	16,4
2015	Sachsen	18,7	–	0,0	0,5	18,2
2015	Sachsen-Anhalt	22,3	2,3	1,1	2,9	16,0
2015	Schleswig-Holstein	6,2	0,1	1,8	0,1	4,3
2015	Thüringen	81,9	0,4	1,8	3,8	75,9
2016	Baden-Württemberg	590,0	2,1	32,2	18,4	537,2
2016	Bayern	3446,2	4,1	5,9	85,7	3350,5
2016	Berlin	0,1	–	–	–	0,1
2016	Brandenburg	64,0	5,5	2,1	22,8	33,6
2016	Hamburg	–	–	–	–	–
2016	Hessen	210,1	0,2	0,5	7,0	202,4
2016	Mecklenburg-Vorpommern	25,1	0,9	4,0	5,6	14,6
2016	Niedersachsen	53,1	4,0	0,8	2,4	46,0
2016	Nordrhein-Westfalen	58,0	5,6	0,4	1,2	50,8
2016	Rheinland-Pfalz	47,6	0,5	0,1	1,6	45,5
2016	Saarland	24,2	1,0	0,8	1,4	21,1
2016	Sachsen	21,7	0,0	0,0	1,9	19,7
2016	Sachsen-Anhalt	40,2	1,4	0,4	3,2	35,2
2016	Schleswig-Holstein	6,8	2,0	0,4	0,3	4,1
2016	Thüringen	80,8	0,1	0,4	1,7	78,6
2017	Baden-Württemberg	920,5	2,7	40,4	15,4	862,0
2017	Bayern	4104,4	2,0	7,0	250,1	3845,3
2017	Berlin	0,1	–	–	–	0,1
2017	Brandenburg	117,0	9,0	1,7	50,5	55,8
2017	Hamburg	0,6	–	–	–	0,6
2017	Hessen	246,3	0,1	0,1	7,8	238,3
2017	Mecklenburg-Vorpommern	19,5	0,5	1,0	1,5	16,6
2017	Niedersachsen	81,8	2,0	0,4	2,7	76,8
2017	Nordrhein-Westfalen	131,3	1,8	0,3	0,5	128,7
2017	Rheinland-Pfalz	124,4	0,5	0,3	1,6	122,0
2017	Saarland	31,5	0,1	0,5	0,6	30,3

2017	Sachsen	29,1	0,0	0,1	0,6	28,4
2017	Sachsen-Anhalt	61,6	2,1	0,8	4,3	54,3
2017	Schleswig-Holstein	10,4	0,5	1,1	0,3	8,5
2017	Thüringen	124,8	–	–	0,2	124,5
2018	Baden-Württemberg	1816,0	4,3	76,4	20,6	1714,7
2018	Bayern	4819,7	1,2	5,6	160,9	4652,0
2018	Berlin	0,1	–	–	–	0,1
2018	Brandenburg	296,1	1,5	0,4	135,7	158,4
2018	Hamburg	0,0	–	–	–	0,0
2018	Hessen	831,5	0,0	0,2	14,9	816,4
2018	Mecklenburg-Vorpommern	54,6	0,6	1,6	2,8	49,6
2018	Niedersachsen	918,6	1,7	2,9	43,8	870,3
2018	Nordrhein-Westfalen	783,0	0,6	0,6	3,4	778,4
2018	Rheinland-Pfalz	576,6	0,2	0,3	1,2	574,8
2018	Saarland	72,5	0,3	0,2	0,5	71,5
2018	Sachsen	263,1	0,4	1,5	26,8	234,4
2018	Sachsen-Anhalt	219,6	0,4	0,7	15,6	202,9
2018	Schleswig-Holstein	48,9	0,5	0,8	3,3	44,3
2018	Thüringen	623,9	0,3	0,1	10,4	613,2
Alle Jahre	Alle Länder	52435,6	339,4	504,3	1787,1	49803,7

Ehrenwörtliche Erklärung

Hiermit erkläre ich, dass die Arbeit selbständig und nur unter Verwendung der angegebenen Hilfsmittel angefertigt wurde.

Ort, Datum

Unterschrift