

Wildtier und Mensch im Naherholungsraum

Eine Analyse verschiedener Einflussfaktoren auf das Besucheraufkommen



Abbildung 1: Fussgängerin im Sihlwald (Stiftung Wildnispark Zürich, o. J.)

Fallstudie Ökosysteme und Biodiversität

verfasst von:

Patricia Casutt und Sophie Keckeis

Umwelt und Natürliche Ressourcen

betreut von:

M.Sc. Adrian Hochreutener

Prof. Dr. Reto Rupf

Januar 2026, Wädenswil

Zusammenfassung

Diese Fallstudie untersucht das Besucheraufkommen im Wildnispark Zürich Sihlwald im Zeitraum von 2016 bis 2023 und analysiert den Einfluss zeitlicher, meteorologischer und gesellschaftlicher Faktoren. Grundlage bilden automatische Besucherzählungen von Fussgänger:innen, ergänzt durch Wetterdaten sowie Informationen zu Schulferien und Phasen der Covid-Pandemie. Die statistische Auswertung mittels eines zeroinflated negativ-Binomialmodells zeigt einen ausgeprägten saisonalen Verlauf mit einem Maximum im Frühjahr und Sommer. Sonnenscheindauer und moderate Temperaturen erhöhen, Niederschlag und sehr hohe Temperaturen reduzieren die Besuchszahlen. Wochenenden und Lockdown-Phasen führen zu deutlichen Nutzungsspitzen, während Schulferien nur einen geringen Effekt haben. Die Ergebnisse verdeutlichen die Relevanz eines gezielten Besucher:innenmanagements zum Schutz störungssensibler Wildtiere.

Inhaltsverzeichnis

1. EINLEITUNG.....	1
2. FORSCHUNGSFRAGEN DIESER ARBEIT	2
3. METHODE	3
3.1 UNTERSUCHUNGSGEBIET	3
3.2 DATENGRUNDLAGE	3
3.3 STATISTISCHE ANALYSE	4
4. RESULTATE.....	6
5. DISKUSSION	10

1. Einleitung

Urbanisierung führt zu einem Verlust natürlicher Lebensräume und drängt Wildtiere in immer kleinere Rückzugsgebiete (Arlettaz et al., 2007; Puri et al., 2024; Reimoser, 2012). Die Folgen sind unter anderem ein alarmierender Rückgang der Biodiversität und die Herausforderung, Wildtiere in einem von Menschen dominierten Umfeld möglichst störungsfreie Existenz zu ermöglichen (Jochum et al., 2014). Freizeitaktivitäten wie Wandern und Mountainbiken verstärken diesen Druck, da sie oft in Rückzugsräumen stattfinden (Visscher et al., 2023).

Daher müssen Wildtiere nicht nur mit vorhersehbaren Umweltschwankungen zurechtkommen, sondern auch mit unvorhersehbaren menschlichen Störungen (Arlettaz et al., 2007). Studien zeigen, dass Tiere ihre Lebensraumnutzung zeitlich anpassen und gestörte Gebiete meiden, insbesondere bei begrenzten Rückzugsmöglichkeiten (Coppes et al., 2017; Gaynor et al., 2018).

Daher ist es wichtig zu untersuchen, wie die zeitliche Besucher:innenstruktur im Wildnispark Zürich Sihlwald störungsarme Phasen beeinflusst und welche Zeitfenster für ein wildtierverschwingendes Management besonders relevant sind.

2. Forschungsfragen dieser Arbeit

Die Arbeit zielt darauf ab, die Dynamik der Besucherfrequenz (Fussgänger:innen) in einem von Menschen beeinflussten Waldgebiet im Mittelland (WPZ – Wildnispark Zürich Sihlwald) unter Berücksichtigung meteorologischer sowie tageszeitlicher Faktoren, Ferien, Feiertage und Phasen der Covid-Pandemie detailliert zu analysieren.

Daher werden in dieser Arbeit folgende Forschungsfragen bearbeitet:

1. Welchen Einfluss haben zeitliche Variablen (Wochentag, Ferien, Monat, Jahr, Phasen der Covid-Pandemie) und Wetterparameter (Sonnenscheindauer, Höchsttemperatur, Niederschlagssumme) auf die Besuchszahlen im WPZ?
2. Wie stark sind die jeweiligen Einflüsse, welche Effektrichtungen sind beobachtbar und welche der untersuchten Parameter sind signifikant?
3. Gibt es in den Effektrichtungen deutliche Unterschiede zwischen den Monaten und wie können diese erklärt werden?

3. Methode

3.1 Untersuchungsgebiet

Der Wildnispark Zürich Sihlwald (WPZ) ist ein beliebter Naherholungsraum auf der Albiskette des schweizerischen Mittellandes. 2010 erhielt der WPZ vom Bundesamt für Umwelt (BAFU) das Label Naturerlebnispark von nationaler Bedeutung (Brändli et al., 2020; Haeler et al., 2023; BAFU, 2025). Die 4 km² grosse Kernzone des Wildnis-parks bietet unberührte und diverse Lebensräume und gilt als Prozessschutz-Gebiet. Umgeben wird diese von einer Übergangszone mit mehr menschlichen Eingriffen (Bauer & Wallner, 2015; Der Schweizerische Bundesrat, 2007; Haeler et al., 2023).

3.2 Datengrundlage

Um der Fragestellung (siehe Kapitel 2) nachzugehen, untersuchten wir die Besuchszahlen des Wildnis-parks Zürich Sihlwald zwischen Ja-nuar 2016 und Dezember 2023 (Da-tensatz bereitgestellt durch den WPZ). Wir fokussierten auf Fuss-gänger:innen bei der Zählstelle 502 (Abb. 2). Die Datenerhebung er-folgte über Infrarotsensoren, rich-tungsgetrennt und in anonymisierter Form.

Die Wetterparameter wurden vom Bundesamt für Meteorologie und Klimatologie, MeteoSchweiz für die Messtation Wädenswil (LV95: 2693847/1230744) auf 485 m.ü.M bezogen (Datensatz Meteo).

Zusätzlich integrierten wir zeitliche Parameter wie die Schulferien der Stadt Zürich sowie Phasen der Covid-Pandemie (Tab.1).




Abbildung 2: Kartenausschnitt Wildnispark Zürich Sihlwald mit der Zählstelle 502.

Tabelle 1: Beschreibung aller erklärenden Variablen (Wetterparameter und zeitliche Parameter), welche in die deskriptive Analyse und die statistische Auswertung einfließen.

Variable	Beschreibung	Datentyp	Wertebereich (min/max)
tre200nx	Temperatur Nacht °C	Numeric	-8.8 bis 32.7
tre200jx	Temperatur Tag °C	Numeric	-7.2 bis 34.8
rre150n0	Niederschlag Nacht mm	Numeric	0 bis 62.6
rre150j0	Niederschlag Tag mm	Numeric	0 bis 54.7
sremaxdv	relative Sonnenscheindauer %	Numeric	0 bis 100
Datum	yyyy-mm-dd	POSIXct	2016-01-01 bis 2023-31-12
Tage_bis_Neujahr	Anzahl Tag bis Ende Jahr	Numeric	1 bis 365/366

Wochentag	Montag bis Sonntag	Factor	1 bis 7
Wochenende	Tage 1 bis 5	Factor	Werktag
	Tage 6 und 7	Factor	Wochenende
KW	Kalenderwoche	Factor	1 bis 52/53
Monat	Januar bis Dezember	Factor	1 bis 12
Jahr	8 Jahre	Factor	2016 bis 2023
Phase	bis zum Lockdown 1	Factor	Pre
	Lockdown	Factor	Lockdown_1
	zwischen den Lockdowns	Factor	Inter
	Lockdown	Factor	Lockdown_2
	ab dem Lockdown 2	Factor	Post
Ferien	Schule	Factor	0
	Ferien	Factor	1
Tageszeit	nightEnd	Factor	Morgen
	goldenHourEnd	Factor	Tag
	goldenHour	Factor	Abend
	night	Factor	Nacht

3.3 Statistische Analyse

Um das Verhalten des Besucheraufkommens im WPZ in Abhängigkeit der verschiedenen Einflussfaktoren (erklärende Variablen) beobachten zu können, führten wir eine deskriptive Datenanalyse durch und generierten eine Reihe von Convenience Variablen (Tab.1). Zur Herstellung einer besseren Vergleichbarkeit der verschiedenen Masseinheiten, skalierten wir die numerischen Wetterparameter mit der Funktion „scale“. Der Test auf Kovarianz mit der Funktion „cor“ ergab ein hochkorrelierendes Paar nach Pearson mit einem Wert von 0.97 (tre200nx und tre200jx). Ausgehend von der Annahme, dass der Einfluss der Nachttemperatur (tre200nx) auf das tägliche Besucheraufkommen einen geringen Einfluss hat, schlossen wir die Variable aus unseren Modellen aus. Anschliessend testeten wir verschiedene Verteilungsfunktionen und erhielten die negativ-Binomialverteilung als beste Annäherung an unsere empirische Datenverteilung. Die negativ-Binomialfunktion wird eingesetzt im Falle von Datensätzen mit Overdispersion. Mit 2.08 skewness ist unsere Datenverteilung rechtsschief. Die meisten Werte liegen im unteren Skalenbereich und wenige Ausreisser verschieben den Mittelwert nach rechts.

Mit der automatischen Variablenselektion und dem Modelaveraging aus dem Packet MuMIN berechneten wir das adäquateste Modell (Bartoń, 2025). Die Berechnung ergab ein bestes Modell unter Ausschluss der skalierten Variable rre150n0 (Niederschlag Nacht). Da die dredge Funktion nicht auskommentiert ist, schlugen wir für die weitere Modellsuche einen robusteren, iterativen Weg ein.

Unser multivariates Modell berechneten wir mit dem 'Generalized Linear Mixed Effects Model' (Brooks et al., 2017). Die Funktion glmmTMB wird als schnell und kompatibel beschrieben und erlaubt diverse Spezifikationen, u.a. den Zugriff auf zeroinflated-Verteilungen (Bolker, 2023). Das minimal adäquate Modell erstellten wir mit der negativ-

Binomialfunktion und den verbleibenden skalierten Variablen `tre200jx` (Temperatur Tag), `rre150j0` (Niederschlag Tag) und `sremaxdv` (Sonnenscheindauer). Die Variable `Tage_bis_Neujahr` diente als „random factor“, mit dem wir den Effekt der Saisonalität testeten. In einem nächsten Schritt quadrierten wir die Tagestemperatur in der Annahme, dass sich sehr hohe Werte negativ auf die Besuchszahlen auswirken können. Gleichzeitig testeten wir auf Interaktionen zwischen verschiedenen Variablen (z.B. Einfluss Niederschlag während Jahreszeiten). Nach einem Residual-Test mittels DHARMA modellierten wir ein zeroinflated Modell (Hartig, 2024). Eine Datentransformation schlossen wir aus, da von verschiedener Seite darauf hingewiesen wird, dass Berechnungen mit `glmmTMB` robuste Modelle auch ohne Transformation liefern können (Schielzeth et al, 2020, Lo, 2015). Mit `AICcmodavg` verglichen wir die Modelle (Mazerolle, 2023). Unser zeroinflated negativ-Binomialmodell ohne Interaktionen erwies sich als bestes Modell.

Mit einer Anova aus dem Packet `car` testeten wir die Signifikanz der Variablen (Fox & Weisberg, 2019), welche für alle im Modell verbliebenen Variablen gegeben war. Für die Modelldiagnostik berechneten und visualisierten wir die Verteilung der Residuen mittels DHARMA ($n=1000$).

Unsere Analyse führten wir in der Open-Source-Statistiksoftware R Version 4.5.1 aus (R Core Team, 2025).

4. Resultate

Die deskriptive Analyse lässt erkennen, dass die Besuchszahlen im WPZ, während der Covid-Pandemie deutlich anstiegen. Während des ersten Lockdowns zwischen Februar und April 2020 stiegen die monatlich aggregierten Passagen der Fussgänger:innen von 2'531 auf 8'811 (Abb. 3). Auch im Jahresvergleich ist ein deutlicher Anstieg der Besucher:innen im Messjahr 2020 zu verzeichnen (Abb. 4). Ebenfalls ist ein deutlicher Unterschied zwischen Werktagen und Wochenenden zu erkennen (Abb. 5). Während in der Pre-Covid Phase am Sonntag der Tageshöchstwert zwischen 14:00 und 15:00 bei 33 Fussgänger:innen lag, stieg dieser während des ersten Lockdowns auf 62.

Die Resultate des zeroinflated negativ-Binomialmodells (Tab.2) zeigen die Bedeutung des Monats Mai mit einem Koeffizienten von 0.61. Ebenfalls führten die erste und zweite Lockdown-Phase (0.62 resp. 0.59) sowie die Wochenenden (0.77) zu einem Anstieg der Besuchszahlen im WPZ. Mit einem negativen Wert führten der Niederschlag (-0.15) und die quadrierte Tagestemperatur (-0.08) zu einem Rückgang der Besuchszahlen. Mit Ausnahme der Monate Februar und November wiesen alle Prädiktoren einen signifikanten p-Wert von höchstens 0.003 auf. Die erklärte Varianz ist mit 95,6 % für den marginalen R^2 Wert und 97,9 % für den conditional R^2 Wert sehr hoch. Insgesamt scheint unser Modell die Unterschiede in der Anzahl Besucher:innen sehr gut zu erklären. Allerdings gibt es im Modell Outliers mit überproportionaler Hebelwirkung, sodass einzelne Datenpunkte die Regressionsfläche verzerren und trügerisch hohe Erklärungsanteile erzeugen könnten. Der random factor Tage_bis_Neujahr hatte nur eine geringfügige Auswirkung auf das Modell. Die zusätzliche Erklärungsleistung durch zufällige Effekte ist mit 2,3 % sehr gering und der Effekt der Saisonalität könnte auch durch die Monate erklärt werden.

In Abbildung 6 sind die Effekte ausgewählter kontinuierlicher und diskreter Variablen visualisiert. Bemerkenswert ist insbesondere der Rückgang der Besuchszahlen bei hohen Temperaturen ab 19 °C. sowie deren Anstieg an Wochenenden und während der Lockdowns. Im monatlichen Verlauf ist ein Höchststand im Mai zu erkennen. Wider Erwarten ist nur ein vernachlässigbarer Unterschied zwischen den Ferien und der Schulzeit zu erkennen (siehe Anhang für weitere Visualisierungen).




Abbildung 3: Verlauf monatliche Besuchszahlen, inkl. Markierung der beiden Lockdowns




Abbildung 4: Verlauf monatliche Besuchszahlen im Jahresvergleich (farblich gekennzeichnet)




Abbildung 5: Besuchszahlen im Tagesverlauf pro Phase und Wochentag (farblich gekennzeichnet)

Tabelle 2: Die Resultate des zeroinflated negativ-Binomialmodells im Überblick. Die Prädiktoren sind in Tabelle 1 beschrieben. Die Spalte Log-Mean gibt die Effektrichtung und -stärke der erklärenden Variablen an. Ein positiver Wert weist auf den Anstieg von Besucher:innen hin, ein negativer Wert auf deren Rückgang. Je höher die Werte, desto stärker der Einfluss der erklärenden Variable. Der p-Wert zeigt die Signifikanz der Variablen im Modell, std. Error ist die Standardabweichung und CI das Konfidenzintervall.

Predictors	Log-Mean	std. Error	Total	CI	p
Count Model					
(Intercept)	4.13	0.04		4.05 – 4.21	<0.001
Monat [2]	0.03	0.04		-0.06 – 0.11	0.531
Monat [3]	0.3	0.05		0.21 – 0.39	<0.001
Monat [4]	0.43	0.05		0.33 – 0.52	<0.001
Monat [5]	0.61	0.05		0.51 – 0.71	<0.001
Monat [6]	0.5	0.06		0.39 – 0.60	<0.001
Monat [7]	0.42	0.06		0.31 – 0.53	<0.001
Monat [8]	0.32	0.06		0.21 – 0.43	<0.001
Monat [9]	0.24	0.05		0.13 – 0.34	<0.001
Monat [10]	0.14	0.05		0.05 – 0.24	0.003
Monat [11]	-0.04	0.04		-0.12 – 0.05	0.417
Monat [12]	-0.18	0.04		-0.26 – -0.10	<0.001
Ferien [1]	0.11	0.02		0.06 – 0.15	<0.001
Phase [Lockdown_1]	0.62	0.05		0.52 – 0.72	<0.001
Phase [Inter]	0.35	0.03		0.30 – 0.40	<0.001
Phase [Lockdown_2]	0.59	0.05		0.50 – 0.68	<0.001
Phase [Post]	0.12	0.02		0.09 – 0.15	<0.001
Wochenende [Wochenende]	0.77	0.02		0.74 – 0.80	<0.001
tre200jx scaled	0.06	0.02		0.03 – 0.10	<0.001
tre200jx scaled^2	-0.08	0.01		-0.09 – -0.06	<0.001
rre150j0 scaled	-0.15	0.01		-0.17 – -0.14	<0.001
sremaxdv scaled	0.23	0.01		0.21 – 0.25	<0.001
(Intercept)	7.95			7.50 – 8.43	
Zero-Inflated Model					
(Intercept)	-21.38	817.29		-1623.24 – 1580.47	0.979
Random Effects					
σ^2					0.01
T00 Tage_bis_Neujahr					0.01
ICC					0.51
N Tage_bis_Neujahr					366
Observations					2899
Marginal R ² / Conditional R ²					0.956 / 0.979




Abbildung 6: Zusammenhang zwischen der Anzahl Besucher:innen im Wildnispark Zürich Sihlwald und den wichtigsten erklärenden Variablen. Niederschlag und Temperatur sind kontinuierliche Wetterparameter. Wochentag, Corona-Phase, Monate und Ferien sind diskrete zeitliche Parameter.

5. Diskussion

Diese Fallstudie zeigt, dass die Besuchszahlen im Sihlwald von saisonalen, meteorologischen und gesellschaftlichen Faktoren beeinflusst werden. Der Monat hat den stärksten Einfluss. Die Anzahl der Besucher:innen nimmt ab dem frühen Frühjahr zu, im Mai wird der Höhepunkt erreicht und bleibt im Sommer erhöht, bevor sie im Herbst und Winter wieder deutlich abnimmt. Dieses Muster deckt sich mit Studien aus anderen europäischen Schutzgebieten, in denen die warme Jahreszeit als Hauptsaison der Erholungsnutzung gilt (Millhäusler et al., 2016).

Meteorologische Faktoren haben ebenfalls einen klaren Einfluss: Regen sowie sehr hohe Temperaturen reduzieren die Besuchszahlen, während Sonnenscheindauer und angenehme Temperaturen diese erhöhen. Solche Zusammenhänge sind aus Freizeitstudien gut bekannt (Arnberger et al., 2010; Fisichelli et al., 2015).

Neben dem Wetter spielen gesellschaftliche Faktoren eine wichtige Rolle bei der Besucherentwicklung. Die höheren Besuchszahlen am Wochenende deuten auf eine grössere zeitliche Verfügbarkeit hin, wie auch Freizeitstudien zeigen (Arnberger et al., 2010). Schulferien hingegen führen zu einem moderaten Anstieg, was darauf hindeutet, dass der Sihlwald primär als alltäglicher Naherholungsraum genutzt wird.

Während der Covid-Lockdowns stiegen die Besuchszahlen stark an, ein international beobachtetes Phänomen, da Schutzgebiete als leicht zugängliche und risikoarme Erholungsräume dienten (Rice et al., 2020). Aus ökologischer Sicht ist dieser erhöhte Nutzungsdruck relevant, da steigende menschliche Präsenz Anpassungen im Raum- und Zeitverhalten von Wildtieren auslösen kann, etwa eine verstärkte nächtliche Aktivität (Gaynor et al., 2018).

Im Wildnispark Zürich Sihlwald sind solche Verhaltensreaktionen besonders relevant, da Reh- und Rotwild sensibel auf menschliche Störungen reagieren. Studien zeigen, dass hohe und unvorhersehbare Besucherintensitäten, insbesondere durch Off-Trail-Nutzung, zu einer Meidung von Wegen, grösseren Abständen zu Störquellen und einer reduzierten Nutzung hochwertiger Habitatbereiche führen (Westekemper et al., 2018; Sibbald et al., 2011). Bereits milde Reize wie Fussgänger:innen lösen messbare Stress- und Verhaltensreaktionen aus, vor allem in energetisch kritischen Phasen wie dem Winter (Reimoser, 2012). Wiederholte Störungen können zudem langfristige physiologische Kosten verursachen (Arlettaz et al., 2007).

Die Ergebnisse dieser Fallstudie fügen sich in dieses Gesamtbild ein: Hohe oder sprunghaft ansteigende Besuchszahlen, wie etwa an Wochenenden, bei gutem Wetter oder während Covid-Lockdowns, erhöhen das Risiko störungsbedingter Verhaltensanpassungen bei Wildtieren und können langfristig die nutzbare Habitatfläche reduzieren (Coppes et al., 2017; Rupf et al., 2011). Die Resultate unterstreichen daher die Notwendigkeit eines zeitlich differenzierten Besucher:innenmanagements, wie unter anderem durch Wegtreue, die Reduktion von Off-Trail-Nutzung, Sensibilisierung der Besucher:innen und eine frühzeitige Kommunikation von Nutzungsspitzen.

Literaturverzeichnis

Arlettaz, R., Patthey, P., Baltic, M., Leu, T., Schaub, M., Palme, R., & Jenni-Eiermann, S. (2007). Spreading free-riding snow sports represent a novel serious threat for wild-life. *Proceedings of the Royal Society B: Biological Sciences*, 274(1614), 1219–1224. <https://doi.org/10.1098/rspb.2006.0434>

Arnberger, A., Aikoh, T., Eder, R., Shoji, Y., & Mieno, T. (2010). How many people should be in the urban forest? A comparison of trail preferences of Vienna and Sapporo forest visitor segments. *Urban Forestry & Urban Greening*, 9(3), 215–225. <https://www.sciencedirect.com/science/article/abs/pii/S1618866710000038>

Bartoń, K. (2025). MuMIn: Multi-model inference (Version 1.48.11) [R package]. CRAN. <https://CRAN.R-project.org/package=MuMIn>

Bauer, N., & Wallner, A. (2015). Wildnis in der Schweiz. Wilderness in Switzerland.

Bolker, B. (2023). Getting started with the glmmTMB package.

Brändli, K., Stillhard, J., Hobi, M., & Brang, P. (2020). Inventur 2017 im Sihlwald (WSL Bericht 93, 52 S.).

Brooks, M. E., Kristensen, K., Van Benthem, K. J., Magnusson, A., Berg, C. W., Nielsen, A., Skaug, H. J., Maechler, M., & Bolker, B. M. (2017). glmmTMB balances speed and flexibility among packages for zero-inflated generalized linear mixed modeling. *The R Journal*, 9(2), 378–400. <https://doi.org/10.32614/RJ-2017-066>

Bundesamt für Umwelt. (2025). Pärke von nationaler Bedeutung. <https://www.bafu.admin.ch/bafu/de/home/themen/landschaft/landschaften-nationaler-bedeutung/paerke-von-nationaler-bedeutung.html>

Coppes, J., Ehrlicher, J., Suchant, R., & Braunisch, V. (2017). Outdoor recreation causes effective habitat reduction in capercaillie *Tetrao urogallus*: A major threat for geographically restricted populations. *Journal of Avian Biology*, 48(1), 1–12. <https://doi.org/10.1111/jav.01239>

Der Schweizerische Bundesrat (2007). Verordnung vom 7. November 2007 über die Pärke von nationaler Bedeutung (Pärkeverordnung, PäV), SR 451.36, Stand 20. Dezember 2025.

Fisichelli, N. A., Schuurman, G. W., Monahan, W. B., & Ziesler, P. S. (2015). Protected area tourism in a changing climate: Will visitation at US national parks warm up or overheat? *PLOS ONE*, 10(6), e0128226.

Fox, J., & Weisberg, S. (2019). An R companion to applied regression (3. Aufl.). Sage. <https://www.john-fox.ca/Companion/>

Gaynor, K. M., Hohnowski, C. E., Carter, N. H., & Brashares, J. S. (2018). The influence of human disturbance on wildlife nocturnality. *Science*, 360(6394), 1232–1235. <https://doi.org/10.1126/science.aar7121>

Haeler, E., Lachat, T., Dumollard, G., Blaser, S., Bergamini, A., Kiebach, T., Scheidegger, C., Keller, C., Stillhard, J., & Hindenlang Clerc, K. (2023). Biodiversitäts-Check im Leuchtturm-Waldreservat Sihlwald. *Schweizerische Zeitschrift für Forstwesen*, 174(S1), s38–s46. <https://doi.org/10.3188/szf.2023.s0038>

Jochum, K. A., Kliskey, A. A., Hundertmark, K. J., & Alessa, L. (2014). Integrating complexity in the management of human-wildlife encounters. *Global Environmental Change*, 26, 73–86. <https://doi.org/10.1016/j.gloenvcha.2014.03.011>

Lo, S., & Andrews, S. (2015). To transform or not to transform: Using generalized linear mixed models to analyse reaction time data. *Frontiers in Psychology*, 6, 1171. <https://doi.org/10.3389/fpsyg.2015.01171>

Mazerolle, M. J. (2023). AICcmodavg: Model selection and multimodel inference based on (Q)AIC(c) (Version 2.3.3) [R package]. CRAN. <https://cran.r-project.org/package=AICcmodavg>

Millhäusler, A., Anderwald, P., Haeni, M., & Haller, R. M. (2016). Publicity, economics and weather – Changes in visitor numbers to a European National Park over 8 years. *Journal of Outdoor Recreation and Tourism*, 16, 50–57.

Puri, M., Johannsen, K. L., Goode, K. O., & Pienaar, E. F. (2024). Addressing the challenge of wildlife conservation in urban landscapes by increasing human tolerance for wildlife. *People and Nature*, 6(3), 1116–1129. <https://doi.org/10.1002/pan3.10604>

R Core Team. (2025). R: A language and environment for statistical computing. R Foundation for Statistical Computing. <http://www.r-project.org/>

Reimoser, S. (2012). Influence of anthropogenic disturbances on activity, behavior and heart rate of roe deer (*Capreolus capreolus*) and red deer (*Cervus elaphus*). In A. A. Cahler & J. P. Marsten (Hrsg.), *Deer: Habitat, behavior and conservation* (S. 1–46). Nova Science Publishers.

Rice, W. L., Mateer, T. J., Reigner, N., Newman, P., Lawhon, B., & Taff, B. D. (2020). Changes in recreational behaviors of outdoor enthusiasts during the COVID-19 pandemic: Analysis across urban and rural communities. *Journal of Urban Ecology*, 6(1), juaa020.

Rupf, R., Wägli, M., Suter, W., & Signer, J. (2011). Habitat selection of capercaillie Tetrao urogallus in relation to human recreation in a Swiss forest reserve. *eco.mont*, 3(1), 55–62. <https://doi.org/10.1553/eco.mont-3-1s55>

Schielzeth, H., Dingemanse, N. J., Nakagawa, S., et al. (2020). Robustness of linear mixed-effects models to violations of distributional assumptions. *Methods in Ecology and Evolution*, 11, 1141–1152. <https://doi.org/10.1111/2041-210X.13434>

Sibbald, A. M., Hooper, R. J., McLeod, J. E., & Gordon, I. J. (2011). Responses of red deer (*Cervus elaphus*) to regular disturbance by hill walkers. *European Journal of Wildlife Research*, 57(5), 817–825. <https://doi.org/10.1007/s10344-011-0493-2>

Sigrist, B., Reifler-Bächtiger, M., Jakob, M., Bar-Gera, B., Suter, S., Graf, R., & Signer, C. (2025). Rothirsch im Mittelland: Bestandsentwicklung und Raumnutzung in der Region Albiskette – Reusstal. ZHAW-Schlussbericht.

Stankowich, T. (2008). Ungulate flight responses to human disturbance: A review and meta-analysis. *Biological Conservation*, 141(9), 2159–2173. <https://doi.org/10.1016/j.biocon.2008.06.026>

Stiftung Wildnispark Zürich. (o. J.). *Feuerstelle Besucherzentrum – Mit Bänken und Brennholz*. Wildnispark Schweiz. <https://www.wildnispark.ch/de/angebote-entdecken/offer-detail/feuerstelle-besucherzentrum-1600>

Visscher, D. R., Walker, P. D., Flowers, M., Kemna, C., Pattison, J., & Kushnerick, B. (2023). Human impact on deer use is greater than predators and competitors in a multiuse recreation area. *Animal Behaviour*, 197, 61–69. <https://doi.org/10.1016/j.anbehav.2023.01.003>

Westekemper, K., Reinecke, H., Signer, J., Meissner, M., Herzog, S., & Balkenhol, N. (2018). Stay on trails – Effects of human recreation on the spatiotemporal behavior of red deer *Cervus elaphus* in a German national park. *Wildlife Biology*, 2018(1). <https://doi.org/10.2981/wlb.00403>

KI-Verweis

Generative KI-Systeme bzw. KI-Tools wurden teilweise zur Zusammenfassung der Literatur verwendet, als Hilfestellung in R für Codes sowie zur grammatischen Kontrolle.

Anhang




Abbildung 7: Verlauf monatliche Besuchszahlen im Tagesverlauf (astronomische Dämmerungszeiten Stadt Zürich) unter Berücksichtigung der Sommer- und Winterzeit




Abbildung 8: Besuchszahlen im Wochengang pro Phase und Tageszeit. Man beachte die logarithmierte Skala der Fussgänger:innen zur besseren Lesbarkeit.

Fallstudie: Besuchermonitoring Sihlwald

Sophie Keckeis und Patricia Casutt

Modul Research Methods, HS25 (Biodiversität und Ökosysteme)

Metadaten und Definitionen

Datenherkunft: Wildnispark Zürich (WPZ) und Bundesamt für Meteorologie und Klimatologie

Datensatz WPZ: Besucherdaten

Bereitgestellt und kalibriert durch den Wildnispark Zürich. Stündlich aufgelöste und richtungsgetrennte Zählraten (Anzahl Passagen Fussgänger:innen und Fahrradfahrer:innen). Zeitraum: Januar 2016 bis Dezember 2023. Zeitangaben: CET/CEST (automatische Umstellung von Sommer auf Winterzeit). Zeitbezug bei Stundenwerten: 11:00 beinhaltet Messperiode von 11:00 bis 11:59.

Datensatz MeteoSchweiz: Meteodaten

Bereitgestellt vom Bundesamt für Meteorologie und Klimatologie, (MeteoSchweiz). Station: Wädenswil (WAE) Länge; 8°41', Breite: 47°13' Koordinaten: 693847/230744 km Höhe: 485 m.ü.M.

Parameter: tre200nx °C: Lufttemperatur 2 m über Boden, Nachtmaximum (18:00 bis 6:00) tre200jx °C: Lufttemperatur 2 m über Boden; Tagmaximum (6:00 bis 18:00) rre150n0 mm: Niederschlag; Halbtagessumme (18:00 bis 6:00) rre150j0 mm: Niederschlag; Halbtagessumme (6:00 bis 18:00) sremaxdv %: Sonnenscheindauer; relativ zur absolut möglichen Tagessumme

Pluviometer: Messung alle 10 Minuten, 1 mm Niederschlag=1 Liter Wasser/m² Zeitangaben in UTC: 00:40 = 02:40 Sommerzeit = 01:40 Winterzeit, 13 beinhaltet Messperiode von 12:01 - 13:00

Datenimport

Dateien von Keckeis Sophie (keckesop), Fallstudie_S

Vorbereitung Projektaufbau

```
library("readr")
library("ggplot2")
library("dplyr")
library("lubridate")
library("suncalc") # berechne Tageszeiten abhaengig vom Sonnenstand
library("ggpubr") # to arrange multiple plots in one graph
library("PerformanceAnalytics") # Plote Korrelationsmatrix
library("MuMIn") # Multi-Model Inference
library("AICcmodavg") # Modellaverageing
library("fitdistrplus") # Prueft die Verteilung in Daten
```

```
library("lme4") # Multivariate Modelle
library("DHARMa") # Modelldiagnostik
library("blme4") # Bayesian data analysis using linear models
library("sjPlot") # Plotten von Modellergebnissen (tab_model)
library("lattice") # einfaches plotten von Zusammenhängen zwischen Variablen
library("glmmTMB") # zero-inflated model
```

```
theme_set(theme_classic())
mycolors <- c("orangered", "gold", "mediumvioletred", "darkblue")
```

```
# Daten laden
schulferien <- read_delim("ferien.csv") # Ferien einlesen und als Schulferien
speichern
schulferien

depo <- read_delim("502_sihluferweg.csv") #Datensatz Sihluferweg (502)
einlesen, als 'depo' speichern
# Zählzeiten bereits bereinigt (Wartungsarbeiten)
# Im Stundenformat Werte bei 11:00:
# Zählzeiten zwischen 11:00 & 12:00 Uhr

meteo=read_delim("order_124839_data.txt") #2a: Meteodaten einlesen
```

```
# Zeitliche Definitionen

depo_start <- as.Date("2016-01-01") # Definition Zeitraum (erster und letzter
Tag )
depo_end <- as.Date("2023-12-31")

lock_1_start_2020 <- as.Date("2020-03-16") # Corona Lockdown, Daten definieren
lock_1_end_2020 <- as.Date("2020-05-11")

lock_2_start_2021 <- as.Date("2020-12-22")
lock_2_end_2021 <- as.Date("2021-03-01")

Erste_Woche <- isoweek(depo_start) # Erste und letzte Kalenderwoche
Untersuchungsfrist
Letzte_Woche <- isoweek(depo_end)
```

Daten(vor)verarbeitung

```
# Besucherzahlen aufbereiten (depo)

str(depo) # Struktur sichten, Kategorien kontrollieren
```

```

spc_tbl_ [70,128 × 5] (S3: spec_tbl_df/tbl_df/tbl/data.frame)
 $ Datetime: num [1:70128] 2.02e+09 2.02e+09 2.02e+09 2.02e+09 2.02e+09 ...
 $ Fuss_IN : num [1:70128] 0 0 0 0 0 ...
 $ Fuss_OUT: num [1:70128] 1.14 0 0 0 0 ...
 $ Velo_IN : num [1:70128] 0 0 0 0 0 ...
 $ Velo_OUT: num [1:70128] 0 0 0 0 0 0 0 0 0 0 ...
- attr(*, "spec")=
 .. cols(
 ..   Datetime = col_double(),
 ..   Fuss_IN = col_double(),
 ..   Fuss_OUT = col_double(),
 ..   Velo_IN = col_double(),
 ..   Velo_OUT = col_double()
 .. )
- attr(*, "problems")=<externalptr>

```

```

# Datum definieren (num->character->Posix), in separate Spalte (Y=Jahr,
m=Monat, d=Tag, H=Stunde)
depo <- depo |>
  mutate(
    Datetime = as.POSIXct(as.character(Datetime), format = "%Y%m%d%H", tz =
"CEt"),
    Datum = as.Date(Datetime)
  )

str(depo)

```

```

tibble [70,128 × 6] (S3: tbl_df/tbl/data.frame)
 $ Datetime: POSIXct[1:70128], format: "2016-01-01 00:00:00" "2016-01-01
01:00:00" ...
 $ Fuss_IN : num [1:70128] 0 0 0 0 0 ...
 $ Fuss_OUT: num [1:70128] 1.14 0 0 0 0 ...
 $ Velo_IN : num [1:70128] 0 0 0 0 0 ...
 $ Velo_OUT: num [1:70128] 0 0 0 0 0 0 0 0 0 0 ...
 $ Datum   : Date[1:70128], format: "2015-12-31" "2016-01-01" ...

```

```

depo <- depo |>
  dplyr::select(-c(Velo_IN, Velo_OUT)) #Spalten (Velo_IN, VELO_OUT entfernen)

depo <- depo |>
  mutate(Total = Fuss_IN + Fuss_OUT) #Total in und out berechnen

depo <- na.omit(depo) # NA's im df entfernen

```

```
# Meteodaten aufbereiten (meteo)
```

```
str(meteo)
```

```
spc_tbl_ [2,922 × 7] (S3: spec_tbl_df/tbl_df/tbl/data.frame)
 $ stn      : chr [1:2922] "WAE" "WAE" "WAE" "WAE" ...
 $ time     : num [1:2922] 20160101 20160102 20160103 20160104 20160105 ...
 $ tre200nx: num [1:2922] 4.9 5 3.7 3.1 5.3 4.6 7.2 5.9 5.8 6.6 ...
 $ tre200jx: num [1:2922] 6 5.8 5.8 4.4 7 6.2 3.5 5.4 7.4 6.7 ...
 $ rre150n0: chr [1:2922] "0.0" "3.9" "6.7" "1.3" ...
 $ rre150j0: chr [1:2922] "0.0" "6.6" "0.3" "9.6" ...
 $ sremaxdv: num [1:2922] 8 0 11 2 51 34 0 0 0 0 ...
 - attr(*, "spec")=
 .. cols(
 ..   stn = col_character(),
 ..   time = col_double(),
 ..   tre200nx = col_double(),
 ..   tre200jx = col_double(),
 ..   rre150n0 = col_character(),
 ..   rre150j0 = col_character(),
 ..   sremaxdv = col_double()
 .. )
 - attr(*, "problems")=<externalptr>
```

```
# Datum als Integer->in Text umwandeln-> Date(), (nicht as.POSIXct)
meteo <- mutate(meteo, time = as.Date(as.character(time), "%Y%m%d"))
str(meteo)
```

```
tibble [2,922 × 7] (S3: tbl_df/tbl/data.frame)
 $ stn      : chr [1:2922] "WAE" "WAE" "WAE" "WAE" ...
 $ time     : Date[1:2922], format: "2016-01-01" "2016-01-02" ...
 $ tre200nx: num [1:2922] 4.9 5 3.7 3.1 5.3 4.6 7.2 5.9 5.8 6.6 ...
 $ tre200jx: num [1:2922] 6 5.8 5.8 4.4 7 6.2 3.5 5.4 7.4 6.7 ...
 $ rre150n0: chr [1:2922] "0.0" "3.9" "6.7" "1.3" ...
 $ rre150j0: chr [1:2922] "0.0" "6.6" "0.3" "9.6" ...
 $ sremaxdv: num [1:2922] 8 0 11 2 51 34 0 0 0 0 ...
```

```
meteo <- meteo |>
  mutate(
    rre150n0 = as.numeric(rre150n0),
    rre150j0 = as.numeric(rre150j0)
  ) |>
  filter(time >= depo_start, time <= depo_end)
```

```
str(meteo)
```

```
tibble [2,922 × 7] (S3: tbl_df/tbl/data.frame)
 $ stn      : chr [1:2922] "WAE" "WAE" "WAE" "WAE" ...
 $ time     : Date[1:2922], format: "2016-01-01" "2016-01-02" ...
 $ tre200nx: num [1:2922] 4.9 5 3.7 3.1 5.3 4.6 7.2 5.9 5.8 6.6 ...
 $ tre200jx: num [1:2922] 6 5.8 5.8 4.4 7 6.2 3.5 5.4 7.4 6.7 ...
 $ rrel50n0: num [1:2922] 0 3.9 6.7 1.3 0.1 4.4 0.6 16 0 8.9 ...
 $ rrel50j0: num [1:2922] 0 6.6 0.3 9.6 0 0 7.9 6.3 5.3 10.7 ...
 $ sremaxdv: num [1:2922] 8 0 11 2 51 34 0 0 0 0 ...
```

```
meteo <- na.omit(meteo) # Werte mit NA filtern
```

```
sum(is.na(meteo)) #Anzahl NA's zeigen
```

```
[1] 0
```

Mutationen

```
# Convenience Variablen erstellen als Faktoren (depo, meteo)
```

```
depo <- depo |>
  mutate(
    Wochentag = wday(Datetime, week_start = 1),
    Wochentag = factor(Wochentag),
    Wochenende = ifelse(Wochentag %in% c(6, 7), "Wochenende", "Werktag"),
    Wochenende = as.factor(Wochenende),
    KW = isoweek(Datetime),
    KW = factor(KW),
    Monat = month(Datetime),
    Monat = factor(Monat),
    Jahr = year(Datetime),
    Jahr = factor(Jahr))
```

```
# Wochentage sortiert (1=Montag, 7=Sonntag)
# 1-5=Wochentag, 6 und 7=Wochenende
# KW=Kalenderwoche
```

```
meteo <- meteo |>
  mutate(
    Wochentag = wday(time, week_start = 1),
    Wochentag = factor(Wochentag),
    Wochenende = ifelse(Wochentag %in% c(6, 7), "Wochenende", "Werktag"),
    Wochenende = as.factor(Wochenende),
    KW = isoweek(time),
```

```
KW = factor(KW),
Monat = month(time),
Monat = factor(Monat),
Jahr = year(time),
Jahr = factor(Jahr))
```

```
# Phasen der Covid-Pandemie definieren
```

```
depo <- depo |>
  mutate(Phase = case_when(
    Datetime < lock_1_start_2020 ~ "Pre",
    Datetime >= lock_1_start_2020 & Datetime <= lock_1_end_2020 ~
      "Lockdown_1",
    Datetime > lock_1_end_2020 & Datetime < lock_2_start_2021 ~ "Inter",
    Datetime >= lock_2_start_2021 & Datetime <= lock_2_end_2021 ~
      "Lockdown_2",
    Datetime > lock_2_end_2021 ~ "Post"
  ))

unique(depo$Phase) # Prüfen
```

```
[1] "Pre"          "Lockdown_1" "Inter"       "Lockdown_2" "Post"
```

```
depo <- depo |>
  mutate(Phase = base::factor(Phase, levels = c("Pre", "Lockdown_1", "Inter",
      "Lockdown_2", "Post")))

# mit factor() Levels definieren, aus R base

str(depo)
```

```
tibble [69,837 × 11] (S3: tbl_df/tbl/data.frame)
 $ Datetime : POSIXct[1:69837], format: "2016-01-01 00:00:00" "2016-01-01
01:00:00" ...
 $ Fuss_IN  : num [1:69837] 0 0 0 0 0 ...
 $ Fuss_OUT : num [1:69837] 1.14 0 0 0 0 ...
 $ Datum    : Date[1:69837], format: "2015-12-31" "2016-01-01" ...
 $ Total    : num [1:69837] 1.14 0 0 0 0 ...
 $ Wochentag : Factor w/ 7 levels "1","2","3","4",...: 5 5 5 5 5 5 5 5 5 ...
 $ Wochenende: Factor w/ 2 levels "Werktag","Wochenende": 1 1 1 1 1 1 1 1 1
1 ...
 $ KW       : Factor w/ 53 levels "1","2","3","4",...: 53 53 53 53 53 53 53 53
53 53 ...
 $ Monat    : Factor w/ 12 levels "1","2","3","4",...: 1 1 1 1 1 1 1 1 1 ...
```

```

$ Jahr      : Factor w/ 8 levels "2016","2017",...: 1 1 1 1 1 1 1 1 1 1 ...
$ Phase     : Factor w/ 5 levels "Pre","Lockdown_1",...: 1 1 1 1 1 1 1 1 1 1
1 ...
- attr(*, "na.action")= 'omit' Named int [1:291] 350 2067 10803 11079 19539
26304 28443 37179 45915 46809 ...
..- attr(*, "names")= chr [1:291] "350" "2067" "10803" "11079" ...

```

```

# Schulferien definieren (wenn >Start und <Ende, dann 1)

for (i in 1:nrow(schulferien)) {
  depo$Ferien[depo$Datum >= schulferien[i, "Start"] & depo$Datum <=
schulferien[i, "Ende"]] <- 1
}
depo$Ferien[is.na(depo$Ferien)] <- 0

depo$Ferien <- factor(depo$Ferien) # als Faktor

```

```

# Stunde als Integer (numerische Stundenauswertungen)

depo$Stunde <- hour(depo$Datetime)
typeof(depo$Stunde)

```

```

# Zahlen runden und als Integer definieren

depo$Total <- as.integer(round(depo$Total, digits = 0))
depo$Fuss_IN <- as.integer(round(depo$Fuss_IN, digits = 0))
depo$Fuss_OUT <- as.integer(round(depo$Fuss_OUT, digits = 0))

```

```

# Einteilung Tageszeit (Dämmerungszeiten Standort Zürich)

Latitude <- 47.38598
Longitude <- 8.50806

# Start und Ende Sommerzeit/Zeitumstellung, Zeitzone Central European Time
(CET/CEST)

# Astronomische Dämmerung und Golden Hour
# - nightEnd: Astronomische Morgendämmerung
# - goldenHourEnd: Ende der morgendlichen golden Hour
# - goldenHour: Beginn der abendlichen golden Hour
# - night: Astronomische Abenddämmerung

lumidata <-
  getSunlightTimes(

```

```

date = seq.Date(depo_start, depo_end, by = 1),
keep = c("nightEnd", "goldenHourEnd", "goldenHour", "night"),
lat = Latitude,
lon = Longitude,
tz = "CET"
) |>
as_tibble()

# Sonnenaufgang, Tageslänge usw. mit Zählzeiten verbinden
depo <- depo |>
  left_join(lumidata, by = c(Datum = "date"))

depo <- depo |>
  mutate(Tageszeit = case_when(
    Datetime >= nightEnd & Datetime <= goldenHourEnd ~ "Morgen",
    Datetime > goldenHourEnd & Datetime < goldenHour ~ "Tag",
    Datetime >= goldenHour & Datetime <= night ~ "Abend",
    .default = "Nacht"
  )) |>
  mutate(Tageszeit = factor(Tageszeit, levels = c("Morgen", "Tag", "Abend",
"Nacht"), ordered = TRUE))

# relevante Variablen
depo <- depo |> dplyr::select(-nightEnd, -goldenHourEnd, -goldenHour, -night,
-lat, -lon)

sum(is.na(depo))


```

```
[1] 0
```

```

# Plotten und überprüfen
ggplot(depo, aes(y = Datetime, color = Tageszeit, x = Stunde)) +
  geom_jitter() +
  scale_color_manual(values = mycolors)

```



```
ggsave(filename="Dämmerung.png", height = 10, width = 20, dpi = 1000, units = "cm")
```

Aggregation der Stundendaten

```
# Stunden pro Nutzergruppe, Richtung und Tag aufsummieren
depo_d <- depo |>
  group_by(Datum) |>
  summarise(
    Total = sum(Fuss_IN + Fuss_OUT),
    Fuss_IN = sum(Fuss_IN),
    Fuss_OUT = sum(Fuss_OUT)
  )

# Anzahl Tage bis Neujahr
depo_d <- depo_d |>
  mutate(Tage_bis_Neujahr = as.numeric(difftime(ymd(paste0(year(Datum),
"-12-31")), Datum, units = "days")))

# Alle convenience Variablen in Tabelle
depo_d <- depo_d |>
  mutate(
    Wochentag = wday(Datum, week_start = 1),
    Wochentag = factor(Wochentag),
    Wochenende = ifelse(Wochentag %in% c(6, 7), "Wochenende", "Werktag"),
    Wochenende = as.factor(Wochenende),
    KW = isoweek(Datum),
    KW = factor(KW),
    Monat = month(Datum),
    Monat = factor(Monat),
    Jahr = year(Datum),
```

```

    Jahr = factor(Jahr))

depo_d <- depo_d |>
  mutate(Phase = case_when(
    Datum < lock_1_start_2020 ~ "Pre",
    Datum >= lock_1_start_2020 & Datum <= lock_1_end_2020 ~ "Lockdown_1",
    Datum > lock_1_end_2020 & Datum < lock_2_start_2021 ~ "Inter",
    Datum >= lock_2_start_2021 & Datum <= lock_2_end_2021 ~ "Lockdown_2",
    Datum > lock_2_end_2021 ~ "Post"
  ))

depo_d <- depo_d |>
  mutate(Phase = base::factor(Phase, levels = c("Pre", "Lockdown_1", "Inter",
"Lockdown_2", "Post")))

for (i in 1:nrow(schulferien)) {
  depo_d$Ferien[depo_d$Datum >= schulferien[i, "Start"] & depo_d$Datum <=
schulferien[i, "Ende"]] <- 1
}
depo_d$Ferien[is.na(depo_d$Ferien)] <- 0

depo_d$Ferien <- factor(depo_d$Ferien)

depo_daytime <- depo |>
  group_by(Jahr, Monat, KW, Phase, Ferien, Wochenende, Tageszeit) |>
  summarise(
    Total = sum(Fuss_IN + Fuss_OUT),
    Fuss_IN = sum(Fuss_IN),
    Fuss_OUT = sum(Fuss_OUT))

mean_phase_d <- depo_daytime |>
  group_by(Phase, Tageszeit) |>
  summarise(
    Total = mean(Total),
    IN = mean(Fuss_IN),
    OUT = mean(Fuss_OUT))

```

```

depo_m <- depo |>
  group_by(Jahr, Monat) |>
  summarise(Total = sum(Total))

depo_m <- depo_m |>
  mutate(
    Ym = paste(Jahr, Monat), # neue Spalte mit Jahr und Monat, als Datum
    Ym = lubridate::ym(Ym)
  )

```


```
# Werte nach Monat und Tageszeit gruppieren, aufsteigend sortieren
depo_m_daytime <- depo |>
  group_by(Jahr, Monat, Tageszeit) |>
  summarise(Total = sum(Total))

depo_m_daytime <- depo_m_daytime |>
  mutate(
    Ym = paste(Jahr, Monat), # neue Spalte mit Jahr und Monat, als Datum
    Ym = lubridate::ym(Ym)
  )
```

Deskriptive Analyse und Visualisierung


```
# Besuchszahlen/Monat inkl. Lockdown 1 (hellblau), Lockdown 2 (hellgrün)

ggplot(depo_m, mapping = aes(Ym, Total, group = 1)) +
  geom_rect(
    mapping = aes(
      xmin = ym("2020-3"), xmax = ym("2020-5"),
      ymin = 0, ymax = max(Total + (Total / 100 * 10))),
    fill = "lightskyblue", alpha = 0.2, colour = NA) +
  geom_rect(
    mapping = aes(
      xmin = ym("2020-12"), xmax = ym("2021-3"),
      ymin = 0, ymax = max(Total + (Total / 100 * 10))),
    fill = "darkolivegreen2", alpha = 0.2, colour = NA) +
  geom_line(alpha = 0.6, linewidth = 1) +
  scale_x_date(date_labels = "%b%y", date_breaks = "6 months") +
  labs(title = "", y = "Fussgänger:innen pro Monat", x = "Jahr") +
  theme_classic(base_size = 15) +
  theme(axis.text.x = element_text(angle = 45, vjust = 1, hjust = 1))
```



```
ggsave(filename="Besucher_Mt.png", height = 10, width = 20, dpi = 1000, units
= "cm")
```


```
ggplot(depo_m, aes(Monat, Total, group = Jahr, color = Jahr, linetype = Jahr))
+
  geom_line(size = 2) +
  geom_point() +
  scale_colour_viridis_d() +
  scale_linetype_manual(values = c(rep("solid", 3), "twodash", "twodash",
"solid", "solid", "solid")) +
  scale_x_discrete(breaks = c(seq(0, 12, by = 1))) +
  geom_vline(xintercept = c(seq(1, 12, by = 1)), linetype = "dashed", color =
"gray") +
  labs(title = "", y = "Fussgänger:innen pro Monat", x = "Monat") +
  theme_classic(base_size = 15) +
  theme(axis.text.x = element_text(angle = 45, vjust = 1, hjust = 1))
```



```
ggsave(filename="Besucher_Jahre.png", height = 10, width = 20, dpi = 1000,
units = "cm")
```

```
ggplot(depo_m_daytime, aes(Ym, Total, fill = Tageszeit)) +
  geom_area(position = "fill", alpha = 0.8) +
  scale_fill_manual(values = mycolors) +
  scale_x_date(date_labels = "%b%y", date_breaks = "6 months",
               limits = c(min(depo_m_daytime$Ym), max =
max(depo_m_daytime$Ym)), expand = c(0, 0)) +
  geom_vline(xintercept = seq(as.Date(min(depo_m_daytime$Ym)),
as.Date(max(depo_m_daytime$Ym)),
               by = "6 months"), linetype = "dashed", color =
```


```
"black")+
  theme_classic(base_size = 15) +
  theme(axis.text.x = element_text(angle = 45, vjust = 1, hjust = 1),
        legend.position = "bottom") +
  labs(title = "", y = "Verteilung Fussgänger:innen / Monat [%]", x = "Jahr")
```



```
ggsave(filename="Verteilung Tageszeit.png", height = 10, width = 20, dpi =
1000, units = "cm")
```

Wochengang

```
ggplot(data = depo, aes(x = Wochentag, y = Total, fill = Tageszeit)) +
  geom_violin(alpha = 0.5) +
  labs(title = "", y = "Fussgänger:innen pro Tag [log10]") +
  facet_grid(cols = vars(Tageszeit), rows = vars(Phase)) +
  scale_y_log10() +
  scale_fill_manual(values = mycolors) +
  theme_classic(base_size = 15) +
  theme(
    panel.background = element_rect(fill = NA, color = "black"),
    axis.text.x = element_text(angle = 45, vjust = 1, hjust = 1),
    legend.title = element_blank(),
    legend.position = "none")
```




```
ggsave(filename="Violinplot.png", height = 10, width = 20, dpi = 1000, units = "cm")
```

Tagesgang

```
Mean_h <- depo |>
  group_by(Wochentag, Stunde, Phase) |>
  summarise(Total = mean(Total))
```

```
ggplot(Mean_h, aes(x = Stunde, y = Total, colour = Wochentag, linetype =
Wochentag)) +
  geom_line(size = 1) +
  scale_colour_viridis_d() +
  scale_linetype_manual(values = c(rep("solid", 5), "twodash", "twodash")) +
  scale_x_continuous(breaks = c(seq(0, 23, by = 1)), labels = c(seq(0, 23, by
= 1))) +
  facet_grid(rows = vars(Phase)) +
  labs(x = "Uhrzeit [h]", y = "Durchschnitt Fussgänger:innen/h", title = "") +
  lims(y = c(0, 65)) +
  theme_linedraw(base_size = 15) +
  theme(axis.text.x = element_text(angle = 45, vjust = 1, hjust = 1))
```



```
ggsave(filename="Tagesgang Jahre.png", height = 10, width = 20, dpi = 1000,
units = "cm")
```

Multifaktorielle Analyse und Visualisierung

```
# Multivariate Modelle

# Verbinden der Datensätze depo_d und meteo (umwelt)

umwelt <- inner_join(depo_d, meteo, by = c("Datum"="time",
"Wochentag"="Wochentag",
"Wochenende"="Wochenende", "KW"="KW", "Monat"="Monat",
"Jahr"="Jahr"))

sum(is.na(umwelt))
```

Skalieren

```
str(umwelt)
is.data.frame(umwelt)
```

```
umwelt <- umwelt |>
  mutate(tre200nx_scaled=scale(tre200nx)) |>
  mutate(tre200jx_scaled = scale(tre200jx))|>
  mutate(rre150n0_scaled = scale(rre150n0) )|>
  mutate(rre150j0_scaled = scale(rre150j0)) |>
  mutate(sremaxdv_scaled=scale(sremaxdv))

# tre200nx: Temperatur Nacht
# tre200jx: Temperatur Tag
```

```
# rre150n0: Niederschlag Nacht
# rre150j0: Niederschlag Tag
# sremaxdv: Sonnenscheindauer relativ zur absolut möglichen Tagessumme
```


Korrelationen und Variablenselektion

```
cor <- cor(subset(umwelt, select = c(tre200nx_scaled:sremaxdv_scaled)))
```

```
cor[abs(cor) < 0.7] <- 0 # alle absoluten Werte kleiner 0.7 = 0
```

```
# Visualisierung Korrelation
```

```
chart.Correlation(subset(umwelt, select =
c(tre200nx_scaled:sremaxdv_scaled)),
  histogram = TRUE, pch = 19)
```



Verteilung der abhängigen Variable prüfen

```
f1 <- fitdist(umwelt$Total, "norm")
f1_1 <- fitdist((umwelt$Total + 1), "lnorm") # Logarithmus(>0)
f2 <- fitdist(umwelt$Total, "pois")
f3 <- fitdist(umwelt$Total, "nbinom") # negativ binomial
f4 <- fitdist(umwelt$Total, "exp")
f5 <- fitdist(umwelt$Total, "gamma") # gamma (Berechnung nicht möglich)
f6 <- fitdist(umwelt$Total, "logis") # logistisch
f7 <- fitdist(umwelt$Total, "geom")
f8 <- fitdist(umwelt$Total, "weibull") # Weibull (Berechnung nicht möglich)

gofstat(list(f1, f2, f3, f4, f6, f7),
  fitnames = c(
```

```
"Normalverteilung", "Poisson",
"negativ binomial", "exponentiell", "logistisch",
"geometrisch"))
```

Goodness-of-fit statistics

	Normalverteilung	Poisson	negativ binomial
Kolmogorov-Smirnov statistic	0.1563292	0.5277102	0.06699036
Cramer-von Mises statistic	26.4837573	235.9253302	3.40041652
Anderson-Darling statistic	150.5741831	Inf	20.72378894

	exponentiell	logistisch	geometrisch
Kolmogorov-Smirnov statistic	0.1662381	0.1249338	0.1715855
Cramer-von Mises statistic	23.2673970	9.9666236	24.7246601
Anderson-Darling statistic	139.9395629	87.8791902	147.4019160

Goodness-of-fit criteria

	Normalverteilung	Poisson	negativ binomial
Akaike's Information Criterion	34800.24	201008.3	32983.41
Bayesian Information Criterion	34812.19	201014.3	32995.36

	exponentiell	logistisch	geometrisch
Akaike's Information Criterion	33693.80	34222.66	33717.34
Bayesian Information Criterion	33699.78	34234.60	33723.31

```
# Statistische Gütemasse: Akaike's Information Criterion (je kleiner AIC,
desto besser), negativ Binomial bestes Modell
```

```
# viele Werte mit 0,1,2 usw, wenige Messungen >200
```

```
# Binomial nachschauen Grafik
```


```
# 2 beste Verteilungen (gemaess AIC) und Normalverteilung
```

```
plot.legend <- c("Normalverteilung", "exponentiell", "negativ binomial")
```

```
# Vergleich theoretische Verteilungen mit empirischen Daten
```

```
cdfcomp(list(f1, f4, f3), legendtext = plot.legend)
```

Empirical and theoretical CDFs



```
# negativ Binomial ist unser bestes Modell gemäss Visualisierung und AIC
(34222.66)
```

Automatische Variablenselektion

```
# Formel für dredge-Funktion (Variable tre200nx (Nachttemperatur) entfernt
f <- Total ~ Wochentag + Ferien + Phase + Monat +
  tre200jx_scaled + rre150j0_scaled + rre150n0_scaled +
  sremaxdv_scaled

# Random-Factor
f_dredge <- paste(c(f, "+ (1|Jahr)"), collapse = " ") |>
  as.formula()

# Modell ausführen
m <- glmer.nb(f_dredge, data = umwelt, na.action = "na.fail")

# Modell in dredge-Funktion einfügen
all_m <- dredge(m)

# bestes Modell (Schwellenwert delta-AIC = 2)
print(all_m, rank = "AICc", subset = delta < 2)
```

```
Global model call: lme4::glmer(formula = Total ~ Wochentag + Ferien + Phase +
Monat +
  tre200jx_scaled + rre150j0_scaled + rre150n0_scaled + sremaxdv_scaled +
  (1 | Jahr), data = umwelt, family = MASS::negative.binomial(theta =
8.57665621433885),
  na.action = "na.fail")
---
```

Model selection table

	(Int)	Frn	Mnt	Phs	rr150j0_scl	rr150n0_scl	srm_scl	t20_scl	Wch	df	logLik
240	4.019	+	+	+	-0.1441		0.2167	0.08676	+	28	-14415.11
256	4.021	+	+	+	-0.1432	-4.586e-03	0.2156	0.08820	+	29	-14414.90
176	3.922	+	+	+	-0.1440		0.2409		+	27	-14429.65
239	4.040		+	+	-0.1448		0.2148	0.09517	+	27	-14430.23
192	3.922	+	+	+	-0.1441	6.064e-04	0.2410		+	28	-14429.64
255	4.042		+	+	-0.1437	-6.009e-03	0.2134	0.09700	+	28	-14429.86
175	3.936		+	+	-0.1447		0.2414		+	26	-14447.87
191	3.936		+	+	-0.1447	-4.299e-04	0.2414		+	27	-14447.87
236	4.123	+	+		-0.1425		0.2188	0.08893	+	24	-14478.53
252	4.124	+	+		-0.1415	-5.134e-03	0.2176	0.09055	+	25	-14478.26
172	4.022	+	+		-0.1423		0.2437		+	23	-14493.89
188	4.022	+	+		-0.1424	2.069e-04	0.2437		+	24	-14493.89
235	4.153		+		-0.1433		0.2167	0.09802	+	23	-14495.37
251	4.155		+		-0.1420	-6.561e-03	0.2152	0.10000	+	24	-14494.93
171	4.044		+		-0.1431		0.2442		+	22	-14514.20
187	4.044		+		-0.1430	-7.919e-04	0.2441		+	23	-14514.20
248	4.058	+	+	+		-2.850e-02	0.2536	0.09519	+	28	-14596.96
232	4.050	+	+	+			0.2619	0.08590	+	27	-14605.76
247	4.078		+	+		-2.986e-02	0.2515	0.10400	+	27	-14612.46
184	3.952	+	+	+		-2.304e-02	0.2812		+	27	-14614.10
168	3.954	+	+	+			0.2857		+	26	-14619.99
231	4.071		+	+			0.2601	0.09461	+	26	-14622.12
183	3.965		+	+		-2.402e-02	0.2817		+	26	-14633.14
167	3.968		+	+			0.2865		+	25	-14639.52
244	4.161	+	+			-2.876e-02	0.2552	0.09683	+	24	-14656.29
228	4.152	+	+				0.2636	0.08744	+	23	-14665.31
243	4.192		+			-3.012e-02	0.2529	0.10640	+	23	-14673.73
180	4.051	+	+			-2.319e-02	0.2833		+	23	-14674.14
164	4.052	+	+				0.2880		+	22	-14680.13
227	4.184		+				0.2616	0.09684	+	22	-14683.62
179	4.074		+			-2.413e-02	0.2838		+	22	-14695.48
163	4.075		+				0.2886		+	21	-14701.96
224	4.185	+	+	+	-0.1830	-3.618e-02		0.29130	+	28	-14708.42
223	4.199		+	+	-0.1831	-3.712e-02		0.29670	+	27	-14718.15
208	4.182	+	+	+	-0.1912			0.28800	+	27	-14722.26
207	4.196		+	+	-0.1915			0.29360	+	26	-14732.72
254	4.315	+		+	-0.1405	-1.499e-02	0.2001	0.24400	+	18	-14778.20
253	4.319			+	-0.1405	-1.548e-02	0.1990	0.24720	+	17	-14780.34
238	4.315	+		+	-0.1433		0.2033	0.24130	+	17	-14780.46
237	4.318			+	-0.1433		0.2022	0.24450	+	16	-14782.75
220	4.291	+	+		-0.1818	-3.687e-02		0.29500	+	24	-14777.39
219	4.314		+		-0.1820	-3.779e-02		0.30070	+	23	-14788.22
204	4.286	+	+		-0.1902			0.29160	+	23	-14791.84
203	4.310		+		-0.1906			0.29760	+	22	-14803.40
250	4.422	+			-0.1386	-1.582e-02	0.2086	0.24150	+	14	-14882.24
234	4.422	+			-0.1415		0.2119	0.23890	+	13	-14884.76

249	4.430				-0.1386	-1.638e-02	0.2073	0.24510	+ 13	-14885.11
233	4.430				-0.1416		0.2106	0.24250	+ 12	-14887.81
160	3.823	+	+	+	-0.2072	-2.937e-02			+ 27	-14926.79
144	3.822	+	+	+	-0.2135				+ 26	-14936.05
246	4.321	+		+		-3.802e-02	0.2424	0.22900	+ 17	-14953.61
245	4.324			+		-3.842e-02	0.2413	0.23200	+ 16	-14955.46
159	3.837		+	+	-0.2080	-3.070e-02			+ 26	-14946.42
143	3.837		+	+	-0.2146				+ 25	-14956.55
230	4.320	+		+			0.2527	0.22070	+ 16	-14969.09
229	4.324			+			0.2517	0.22380	+ 15	-14971.29
156	3.914	+	+		-0.2062	-2.992e-02			+ 23	-15002.78
140	3.913	+	+		-0.2126				+ 22	-15012.45
155	3.937		+		-0.2070	-3.120e-02			+ 22	-15024.35
216	4.273	+	+	+		-7.325e-02		0.34990	+ 27	-15027.43
139	3.936		+		-0.2137				+ 21	-15034.88
215	4.284		+	+		-7.410e-02		0.35520	+ 26	-15036.89
242	4.427	+				-3.869e-02	0.2503	0.22630	+ 13	-15052.40
241	4.435					-3.915e-02	0.2491	0.22970	+ 12	-15055.04
226	4.427	+					0.2608	0.21840	+ 12	-15068.48
221	4.339			+	-0.1881	-4.578e-02		0.35040	+ 16	-15065.97
225	4.435						0.2595	0.22200	+ 11	-15071.52
222	4.338	+		+	-0.1881	-4.571e-02		0.34990	+ 17	-15065.87
205	4.339			+	-0.1985			0.34760	+ 15	-15087.85
206	4.338	+		+	-0.1986			0.34690	+ 16	-15087.68
200	4.273	+	+	+				0.34710	+ 26	-15089.71
212	4.382	+	+			-7.371e-02		0.35240	+ 23	-15092.82
211	4.404		+			-7.452e-02		0.35800	+ 22	-15103.57
199	4.286		+	+				0.35280	+ 25	-15100.61
196	4.377	+	+					0.34950	+ 22	-15156.21
195	4.402		+					0.35570	+ 21	-15168.35
190	4.288	+		+	-0.1201	1.404e-02	0.3268		+ 17	-15175.21
174	4.289	+		+	-0.1173		0.3250		+ 16	-15177.32
217	4.439				-0.1890	-4.775e-02		0.35040	+ 12	-15198.34
218	4.437	+			-0.1891	-4.766e-02		0.34950	+ 13	-15198.10
189	4.295			+	-0.1188	1.355e-02	0.3284		+ 16	-15201.00
173	4.295			+	-0.1162		0.3267		+ 15	-15202.96
201	4.440				-0.2000			0.34790	+ 11	-15222.21
202	4.437	+			-0.2001			0.34690	+ 12	-15221.85
186	4.427	+			-0.1166	1.238e-02	0.3369		+ 13	-15292.54
170	4.428	+			-0.1141		0.3354		+ 12	-15294.17
166	4.296	+		+			0.3584		+ 15	-15307.46
182	4.296	+		+		-6.652e-03	0.3572		+ 16	-15306.96
185	4.453				-0.1152	1.185e-02	0.3389		+ 12	-15322.17
169	4.454				-0.1129		0.3374		+ 11	-15323.66
165	4.302			+			0.3597		+ 14	-15330.38
181	4.302			+		-6.717e-03	0.3585		+ 15	-15329.87
152	3.838	+	+	+		-6.894e-02			+ 26	-15348.72
151	3.851		+	+		-7.032e-02			+ 25	-15370.36

213	4.351			+		-8.541e-02		0.36080	+ 15	-15410.78
214	4.352	+		+		-8.543e-02		0.36100	+ 16	-15410.77
162	4.431	+					0.3677		+ 11	-15417.50
178	4.431	+				-7.966e-03	0.3663		+ 12	-15416.78
136	3.839	+	+	+					+ 25	-15405.00
148	3.929	+	+			-6.930e-02			+ 22	-15420.69
135	3.853		+	+					+ 24	-15428.93
161	4.456						0.3693		+ 10	-15444.08
177	4.456					-8.031e-03	0.3679		+ 11	-15443.35
147	3.952		+			-7.060e-02			+ 21	-15444.66
132	3.927	+	+						+ 21	-15477.91
197	4.353			+				0.35470	+ 14	-15494.57
198	4.353	+		+				0.35470	+ 15	-15494.57
131	3.952		+						+ 20	-15504.05
209	4.448					-8.769e-02		0.35960	+ 11	-15546.10
210	4.448	+				-8.767e-02		0.35950	+ 12	-15546.09
193	4.450							0.35420	+ 10	-15634.80
194	4.448	+						0.35380	+ 11	-15634.74
128	4.327	+	+	+	-0.1467	1.003e-02	0.2114	0.08378	23	-16119.19
112	4.330	+	+	+	-0.1448		0.2091	0.08688	22	-16120.25
64	4.233	+	+	+	-0.1473	1.473e-02	0.2353		22	-16132.73
48	4.233	+	+	+	-0.1446		0.2332		21	-16135.08
111	4.365		+	+	-0.1457		0.2060	0.09977	21	-16156.10
127	4.363		+	+	-0.1473	8.424e-03	0.2080	0.09723	22	-16155.35
108	4.417	+	+		-0.1435		0.2108	0.08690	18	-16174.53
124	4.414	+	+		-0.1452	8.866e-03	0.2129	0.08416	19	-16173.69
63	4.257		+	+	-0.1481	1.380e-02	0.2358		21	-16173.75
47	4.256		+	+	-0.1455		0.2337		20	-16175.81
60	4.319	+	+		-0.1458	1.360e-02	0.2371		18	-16187.41
44	4.318	+	+		-0.1432		0.2351		17	-16189.42
158	4.316	+		+	-0.2057	-2.509e-02			+ 16	-16205.80
142	4.316	+		+	-0.2110				+ 15	-16212.95
107	4.464		+		-0.1446		0.2074	0.10050	17	-16212.76
123	4.462		+		-0.1460	7.215e-03	0.2091	0.09836	18	-16212.21
59	4.353		+		-0.1468	1.266e-02	0.2374		17	-16231.14
43	4.352		+		-0.1444		0.2355		16	-16232.88
157	4.323			+	-0.2050	-2.584e-02			+ 15	-16241.11
141	4.323			+	-0.2104				+ 14	-16248.72
120	4.368	+	+	+		-1.411e-02	0.2508	0.08934	22	-16312.09
104	4.364	+	+	+			0.2549	0.08486	21	-16314.35
40	4.269	+	+	+			0.2783		20	-16328.46
56	4.268	+	+	+		-9.266e-03	0.2765		21	-16327.47
119	4.404		+	+		-1.557e-02	0.2476	0.10270	21	-16349.12
103	4.400		+	+			0.2521	0.09788	20	-16351.86
116	4.454	+	+			-1.499e-02	0.2521	0.08918	18	-16363.07
100	4.450	+	+				0.2564	0.08441	17	-16365.62
55	4.292		+	+		-1.008e-02	0.2771		20	-16369.61
39	4.293		+	+			0.2791		19	-16370.78

52	4.353	+	+			-1.014e-02	0.2778		17	-16378.45
36	4.354	+	+				0.2798		16	-16379.64
154	4.467	+			-0.2053	-2.860e-02			+ 12	-16400.66
115	4.502		+			-1.651e-02	0.2485	0.10330	17	-16402.85
138	4.466	+			-0.2113				+ 11	-16409.94
99	4.498		+				0.2533	0.09820	16	-16405.95
96	4.488	+	+	+	-0.1866	-1.988e-02		0.28270	22	-16407.31
80	4.486	+	+	+	-0.1912			0.28090	21	-16411.67
51	4.388		+			-1.097e-02	0.2783		16	-16423.69
35	4.389		+				0.2805		15	-16425.09
153	4.499				-0.2046	-2.951e-02			+ 11	-16443.37
95	4.515		+	+	-0.1868	-2.092e-02		0.29180	21	-16434.87
79	4.513		+	+	-0.1915			0.29000	20	-16439.71
137	4.499				-0.2108				+ 10	-16453.28
92	4.578	+	+		-0.1855	-2.110e-02		0.28410	18	-16465.41
76	4.576	+	+		-0.1903			0.28220	17	-16470.35
91	4.617		+		-0.1857	-2.212e-02		0.29340	17	-16494.40
75	4.614		+		-0.1908			0.29160	16	-16499.83
110	4.617	+		+	-0.1458		0.1992	0.23370	11	-16512.87
126	4.617	+		+	-0.1460	8.494e-04	0.1994	0.23350	12	-16512.86
109	4.626			+	-0.1458		0.1967	0.24070	10	-16523.95
125	4.626			+	-0.1458	-1.965e-05	0.1967	0.24070	11	-16523.95
106	4.694	+			-0.1448		0.2054	0.23110	7	-16600.63
122	4.694	+			-0.1446	-6.635e-04	0.2052	0.23120	8	-16600.63
105	4.711				-0.1448		0.2027	0.23860	6	-16613.28
121	4.711				-0.1445	-1.598e-03	0.2023	0.23890	7	-16613.25
32	4.135	+	+	+	-0.2095	-1.384e-02			21	-16615.58
16	4.135	+	+	+	-0.2125				20	-16617.73
150	4.331	+		+		-6.229e-02			+ 15	-16641.13
31	4.159		+	+	-0.2106	-1.507e-02			20	-16658.42
15	4.159		+	+	-0.2138				19	-16660.96
149	4.338			+		-6.255e-02			+ 14	-16673.52
28	4.216	+	+		-0.2085	-1.499e-02			17	-16677.12
12	4.215	+	+		-0.2117				16	-16679.65
134	4.332	+		+					+ 14	-16689.31
118	4.627	+		+		-2.253e-02	0.2433	0.21830	11	-16703.66
102	4.626	+		+			0.2494	0.21330	10	-16709.30
117	4.636			+		-2.319e-02	0.2407	0.22520	10	-16713.96
101	4.636			+			0.2470	0.22020	9	-16719.94
133	4.340			+					+ 13	-16722.17
27	4.249		+		-0.2097	-1.618e-02			16	-16722.04
11	4.249		+		-0.2132				15	-16724.99
88	4.585	+	+	+		-5.706e-02		0.34100	21	-16743.11
87	4.609		+	+		-5.791e-02		0.34990	20	-16770.19
114	4.703	+				-2.392e-02	0.2490	0.21550	7	-16787.56
98	4.703	+					0.2555	0.21050	6	-16793.93
72	4.585	+	+	+				0.33920	20	-16782.45
113	4.720					-2.465e-02	0.2462	0.22290	6	-16799.58

97	4.720					0.2528	0.21790	5	-16806.35
94	4.648	+		+	-0.1939	-2.909e-02	0.34020	11	-16803.11
84	4.675	+	+			-5.801e-02	0.34150	17	-16797.88
93	4.653			+	-0.1934	-2.936e-02	0.34390	10	-16807.79
78	4.647	+		+	-0.2005		0.33840	10	-16812.29
77	4.653			+	-0.2001		0.34210	9	-16817.15
71	4.611		+	+			0.34840	19	-16810.69
83	4.713		+			-5.884e-02	0.35070	16	-16826.73
146	4.478	+				-6.616e-02		+	11 -16835.60
68	4.674	+	+				0.33970	16	-16838.69
67	4.713		+				0.34920	15	-16868.72
145	4.509					-6.652e-02		+	10 -16875.24
62	4.591	+		+	-0.1268	2.751e-02	0.3201	11	-16877.45
46	4.591	+		+	-0.1215		0.3167	10	-16885.83
130	4.477	+						+	10 -16889.92
90	4.713	+			-0.1948	-3.133e-02	0.33830	7	-16910.36
89	4.724				-0.1944	-3.162e-02	0.34230	6	-16915.74
74	4.713	+			-0.2020		0.33650	6	-16921.02
73	4.724				-0.2016		0.34060	5	-16926.61
61	4.608			+	-0.1250	2.734e-02	0.3223	10	-16924.06
129	4.509							+	9 -16930.28
45	4.608			+	-0.1198		0.3189	9	-16932.37
58	4.694	+			-0.1237	2.583e-02	0.3279	7	-16978.11
42	4.694	+			-0.1187		0.3247	6	-16985.48
38	4.602	+		+			0.3514	9	-17025.83
54	4.602	+		+		6.253e-03	0.3525	10	-17025.37
57	4.730				-0.1218	2.561e-02	0.3304	6	-17030.12
41	4.730				-0.1169		0.3272	5	-17037.40
24	4.160	+	+	+		-5.382e-02		20	-17051.82
37	4.619			+			0.3531	8	-17068.17
53	4.619			+		6.686e-03	0.3542	9	-17067.65
8	4.161	+	+	+				19	-17087.49
23	4.184		+	+		-5.501e-02		19	-17097.52
34	4.702	+					0.3585	5	-17119.37
50	4.702	+				4.846e-03	0.3593	6	-17119.09
20	4.238	+	+			-5.471e-02		16	-17109.39
7	4.185		+	+				18	-17134.77
4	4.238	+	+					15	-17146.40
33	4.736						0.3605	4	-17166.85
49	4.736					5.263e-03	0.3614	5	-17166.52
19	4.273		+			-5.584e-02		15	-17157.75
86	4.673	+		+		-6.919e-02	0.35270	10	-17172.03
85	4.677			+		-6.925e-02	0.35560	9	-17174.91
3	4.274		+					14	-17196.31
70	4.674	+		+			0.34770	9	-17228.89
69	4.678			+			0.35060	8	-17231.88
82	4.731	+				-7.171e-02	0.34930	6	-17282.92
81	4.740					-7.178e-02	0.35250	5	-17286.50

66	4.734	+				0.34450	5	-17344.19
65	4.743					0.34780	4	-17347.93
30	4.626	+	+	-0.2119	-1.069e-02		10	-17885.69
14	4.626	+	+	-0.2141			9	-17887.04
29	4.646		+	-0.2110	-1.090e-02		9	-17944.86
13	4.646		+	-0.2133			8	-17946.27
26	4.734	+		-0.2112	-1.357e-02		6	-18043.27
10	4.734	+		-0.2141			5	-18045.44
25	4.776			-0.2103	-1.389e-02		5	-18111.53
9	4.776			-0.2132			4	-18113.81
22	4.652	+	+		-4.819e-02		9	-18352.37
6	4.653	+	+				8	-18382.18
21	4.673		+		-4.769e-02		8	-18407.59
5	4.674		+				7	-18436.90
18	4.757	+			-5.129e-02		5	-18508.20
2	4.758	+					4	-18541.96
17	4.796				-5.086e-02		4	-18572.29
1	4.798						3	-18605.61
	AICc	delta	weight					
240	28886.8	0.00	0.692					
256	28888.4	1.61	0.308					
176	28913.8	27.03	0.000					
239	28915.0	28.19	0.000					
192	28915.9	29.06	0.000					
255	28916.3	29.50	0.000					
175	28948.2	61.43	0.000					
191	28950.3	63.47	0.000					
236	29005.5	118.68	0.000					
252	29007.0	120.18	0.000					
172	29034.2	147.37	0.000					
188	29036.2	149.40	0.000					
235	29037.1	150.33	0.000					
251	29038.3	151.49	0.000					
171	29072.8	185.96	0.000					
187	29074.8	187.98	0.000					
248	29250.5	363.69	0.000					
232	29266.1	379.26	0.000					
247	29279.4	392.65	0.000					
184	29282.7	395.94	0.000					
168	29292.5	405.67	0.000					
231	29296.7	409.94	0.000					
183	29318.8	431.97	0.000					
167	29329.5	442.70	0.000					
244	29361.0	474.21	0.000					
228	29377.0	490.22	0.000					
243	29393.8	507.05	0.000					
180	29394.7	507.86	0.000					
164	29404.6	517.82	0.000					

227	29411.6	524.81	0.000
179	29435.3	548.52	0.000
163	29446.2	559.45	0.000
224	29473.4	586.61	0.000
223	29490.8	604.02	0.000
208	29499.0	612.25	0.000
207	29517.9	631.14	0.000
254	29592.6	705.85	0.000
253	29594.9	708.09	0.000
238	29595.1	708.33	0.000
237	29597.7	710.89	0.000
220	29603.2	716.41	0.000
219	29622.8	736.02	0.000
204	29630.1	743.27	0.000
203	29651.1	764.36	0.000
250	29792.6	905.84	0.000
234	29795.7	908.86	0.000
249	29796.3	909.55	0.000
233	29799.7	912.94	0.000
160	29908.1	1021.31	0.000
144	29924.6	1037.79	0.000
246	29941.4	1054.63	0.000
245	29943.1	1056.32	0.000
159	29945.3	1058.54	0.000
143	29963.5	1076.76	0.000
230	29970.4	1083.58	0.000
229	29972.8	1085.96	0.000
156	30051.9	1165.15	0.000
140	30069.3	1182.47	0.000
155	30093.1	1206.27	0.000
216	30109.4	1222.59	0.000
139	30112.1	1225.28	0.000
215	30126.3	1239.47	0.000
242	30130.9	1244.13	0.000
241	30134.2	1247.39	0.000
226	30161.1	1274.28	0.000
221	30164.1	1277.33	0.000
225	30165.1	1278.35	0.000
222	30166.0	1279.16	0.000
205	30205.9	1319.07	0.000
206	30207.5	1320.75	0.000
200	30231.9	1345.11	0.000
212	30232.0	1345.24	0.000
211	30251.5	1364.69	0.000
199	30251.7	1364.87	0.000
196	30356.8	1469.97	0.000
195	30379.0	1492.24	0.000
190	30384.6	1497.85	0.000

174	30386.8	1500.03	0.000
217	30420.8	1534.00	0.000
218	30422.3	1535.53	0.000
189	30434.2	1547.39	0.000
173	30436.1	1549.29	0.000
201	30466.5	1579.71	0.000
202	30467.8	1581.02	0.000
186	30611.2	1724.42	0.000
170	30612.5	1725.66	0.000
166	30645.1	1758.29	0.000
182	30646.1	1759.31	0.000
185	30668.4	1781.65	0.000
169	30669.4	1782.62	0.000
165	30688.9	1802.12	0.000
181	30689.9	1803.12	0.000
152	30749.9	1863.13	0.000
151	30791.2	1904.39	0.000
213	30851.7	1964.94	0.000
214	30853.7	1966.94	0.000
162	30857.1	1970.30	0.000
178	30857.7	1970.88	0.000
136	30860.5	1973.66	0.000
148	30885.7	1998.93	0.000
135	30906.3	2019.48	0.000
161	30908.2	2021.44	0.000
177	30908.8	2021.99	0.000
147	30931.6	2044.84	0.000
132	30998.1	2111.34	0.000
197	31017.3	2130.49	0.000
198	31019.3	2132.51	0.000
131	31048.4	2161.61	0.000
209	31114.3	2227.51	0.000
210	31116.3	2229.50	0.000
193	31289.7	2402.87	0.000
194	31291.6	2404.78	0.000
128	32284.8	3397.97	0.000
112	32284.9	3398.07	0.000
64	32309.8	3423.01	0.000
48	32312.5	3425.68	0.000
111	32354.5	3467.73	0.000
127	32355.0	3468.25	0.000
108	32385.3	3498.50	0.000
124	32385.6	3498.85	0.000
63	32389.8	3503.02	0.000
47	32391.9	3505.11	0.000
60	32411.1	3524.27	0.000
44	32413.1	3526.27	0.000
158	32443.8	3556.99	0.000

142	32456.1	3569.28	0.000
107	32459.7	3572.95	0.000
123	32460.7	3573.86	0.000
59	32496.5	3609.69	0.000
43	32497.9	3611.15	0.000
157	32512.4	3625.59	0.000
141	32525.6	3638.79	0.000
120	32668.5	3781.75	0.000
104	32671.0	3784.23	0.000
40	32697.2	3810.42	0.000
56	32697.3	3810.47	0.000
119	32740.6	3853.77	0.000
103	32744.0	3857.22	0.000
116	32762.4	3875.57	0.000
100	32765.4	3878.66	0.000
55	32779.5	3892.72	0.000
39	32779.8	3893.03	0.000
52	32791.1	3904.32	0.000
36	32791.5	3904.68	0.000
154	32825.4	3938.64	0.000
115	32839.9	3953.13	0.000
138	32842.0	3955.19	0.000
99	32844.1	3957.30	0.000
96	32859.0	3972.17	0.000
80	32865.7	3978.88	0.000
51	32879.6	3992.78	0.000
35	32880.3	3993.55	0.000
153	32908.8	4022.04	0.000
95	32912.1	4025.26	0.000
79	32919.7	4032.91	0.000
137	32926.6	4039.85	0.000
92	32967.1	4080.26	0.000
76	32974.9	4088.11	0.000
91	33023.0	4136.22	0.000
75	33031.9	4145.06	0.000
110	33047.8	4161.04	0.000
126	33049.8	4163.04	0.000
109	33068.0	4181.18	0.000
125	33070.0	4183.19	0.000
106	33215.3	4328.52	0.000
122	33217.3	4330.52	0.000
105	33238.6	4351.79	0.000
121	33240.5	4353.75	0.000
32	33273.5	4386.70	0.000
16	33275.8	4388.96	0.000
150	33312.4	4425.64	0.000
31	33357.1	4470.33	0.000
15	33360.2	4473.40	0.000

149	33375.2	4488.39	0.000
28	33388.5	4501.66	0.000
12	33391.5	4504.70	0.000
134	33406.8	4519.96	0.000
118	33429.4	4542.62	0.000
102	33438.7	4551.89	0.000
117	33448.0	4561.20	0.000
101	33457.9	4571.15	0.000
133	33470.5	4583.68	0.000
27	33476.3	4589.48	0.000
11	33480.2	4593.36	0.000
88	33528.5	4641.76	0.000
87	33580.7	4693.88	0.000
114	33589.2	4702.38	0.000
98	33599.9	4713.10	0.000
72	33605.2	4718.41	0.000
113	33611.2	4724.40	0.000
97	33622.7	4735.94	0.000
94	33628.3	4741.52	0.000
84	33630.0	4743.17	0.000
93	33635.7	4748.86	0.000
78	33644.7	4757.86	0.000
77	33652.4	4765.56	0.000
71	33659.7	4772.86	0.000
83	33685.7	4798.86	0.000
146	33693.3	4806.49	0.000
68	33709.6	4822.78	0.000
67	33767.6	4880.81	0.000
145	33770.5	4883.75	0.000
62	33777.0	4890.21	0.000
46	33791.7	4904.94	0.000
130	33799.9	4913.12	0.000
90	33834.8	4947.96	0.000
89	33843.5	4956.72	0.000
74	33854.1	4967.28	0.000
73	33863.2	4976.45	0.000
61	33868.2	4981.40	0.000
129	33878.6	4991.82	0.000
45	33882.8	4996.01	0.000
58	33970.3	5083.47	0.000
42	33983.0	5096.20	0.000
38	34069.7	5182.93	0.000
54	34070.8	5184.02	0.000
57	34072.3	5185.47	0.000
41	34084.8	5198.02	0.000
24	34143.9	5257.13	0.000
37	34152.4	5265.60	0.000
53	34153.4	5266.56	0.000

```

8  34213.2 5326.45 0.000
23 34233.3 5346.51 0.000
34 34248.8 5361.97 0.000
50 34250.2 5363.42 0.000
20 34251.0 5364.17 0.000
7  34305.8 5418.98 0.000
4  34323.0 5436.18 0.000
33 34341.7 5454.91 0.000
49 34343.1 5456.27 0.000
19 34345.7 5458.87 0.000
86 34364.1 5477.35 0.000
85 34367.9 5481.08 0.000
3  34420.8 5533.97 0.000
70 34475.8 5589.04 0.000
69 34479.8 5593.03 0.000
82 34577.9 5691.07 0.000
81 34583.0 5696.23 0.000
66 34698.4 5811.61 0.000
65 34703.9 5817.08 0.000
30 35791.5 6904.66 0.000
14 35792.1 6905.35 0.000
29 35907.8 7021.00 0.000
13 35908.6 7021.80 0.000
26 36098.6 7211.78 0.000
10 36100.9 7214.11 0.000
25 36233.1 7346.28 0.000
9  36235.6 7348.85 0.000
22 36722.8 7836.00 0.000
6  36780.4 7893.61 0.000
21 36831.2 7944.44 0.000
5  36887.8 8001.05 0.000
18 37026.4 8139.63 0.000
2  37091.9 8205.14 0.000
17 37152.6 8265.80 0.000
1  37217.2 8330.44 0.000

```

Models ranked by AICc(x)
Random terms (all models):
1 | Jahr

```

# Importance Values Variablen
MuMIn::sw(all_m)

```

	Monat	Phase	rre150j0_scaled	sremaxdv_scaled	Wochentag
Sum of weights:	1.00	1.00	1.00	1.00	1.00
N containing models:	128	128	128	128	128
	Ferien	tre200jx_scaled	rre150n0_scaled		

Sum of weights:	1.00	1.00	0.31
N containing models:	128	128	128

```
# Modelaverage durchführen (Schwellenwert delta-AIC = 2)
avgmodel <- model.avg(all_m, rank = "AICc", subset = delta < 2)

summary(avgmodel)
```

Call:

```
model.avg(object = get.models(object = all_m, subset = delta <
  2), rank = "AICc")
```

Component model call:

```
lme4::glmer(formula = Total ~ <2 unique rhs>, data = umwelt, family =
  MASS::negative.binomial(theta = 8.57665621433885), na.action = na.fail)
```

Component models:

	df	logLik	AICc	delta	weight
1234678	28	-14415.11	28886.79	0.00	0.69
12345678	29	-14414.90	28888.41	1.61	0.31

Term codes:

	Ferien	Monat	Phase rre150j0_scaled
rre150n0_scaled			
	1	2	3
5			4
sremaxdv_scaled			
tre200jx_scaled			
	6	7	8
			Wochentag

Model-averaged coefficients:

(full average)

	Estimate	Std. Error	Adjusted SE	z value	Pr(> z)
(Intercept)	4.019823	0.046090	0.046110	87.179	< 2e-16 ***
Ferien1	0.108519	0.019824	0.019833	5.472	< 2e-16 ***
Monat2	0.077982	0.034071	0.034085	2.288	0.02215 *
Monat3	0.369462	0.035947	0.035962	10.274	< 2e-16 ***
Monat4	0.504939	0.038860	0.038877	12.988	< 2e-16 ***
Monat5	0.677191	0.041794	0.041811	16.196	< 2e-16 ***
Monat6	0.474625	0.048342	0.048362	9.814	< 2e-16 ***
Monat7	0.374485	0.049358	0.049378	7.584	< 2e-16 ***
Monat8	0.280835	0.048672	0.048693	5.767	< 2e-16 ***
Monat9	0.273891	0.043979	0.043998	6.225	< 2e-16 ***
Monat10	0.219709	0.038770	0.038787	5.665	< 2e-16 ***
Monat11	0.017982	0.035559	0.035574	0.505	0.61323
Monat12	-0.168035	0.033889	0.033903	4.956	7e-07 ***

PhaseLockdown_1	0.566332	0.061172	0.061197	9.254	< 2e-16	***
PhaseInter	0.282667	0.045752	0.045771	6.176	< 2e-16	***
PhaseLockdown_2	0.456221	0.062628	0.062654	7.282	< 2e-16	***
PhasePost	0.148027	0.052636	0.052658	2.811	0.00494	**
rrel150j0_scaled	-0.143840	0.006924	0.006927	20.766	< 2e-16	***
sremadv_scaled	0.216378	0.008874	0.008878	24.372	< 2e-16	***
tre200jx_scaled	0.087202	0.016154	0.016160	5.396	1e-07	***
Wochentag2	0.048510	0.025141	0.025152	1.929	0.05377	.
Wochentag3	0.006901	0.025136	0.025147	0.274	0.78376	
Wochentag4	0.007289	0.025133	0.025144	0.290	0.77191	
Wochentag5	-0.014296	0.025122	0.025133	0.569	0.56948	
Wochentag6	0.495827	0.024867	0.024878	19.931	< 2e-16	***
Wochentag7	0.996292	0.024750	0.024760	40.237	< 2e-16	***
rrel150n0_scaled	-0.001415	0.004430	0.004431	0.319	0.74955	

(conditional average)

	Estimate	Std. Error	Adjusted SE	z value	Pr(> z)	
(Intercept)	4.019823	0.046090	0.046110	87.179	< 2e-16	***
Ferien1	0.108519	0.019824	0.019833	5.472	< 2e-16	***
Monat2	0.077982	0.034071	0.034085	2.288	0.02215	*
Monat3	0.369462	0.035947	0.035962	10.274	< 2e-16	***
Monat4	0.504939	0.038860	0.038877	12.988	< 2e-16	***
Monat5	0.677191	0.041794	0.041811	16.196	< 2e-16	***
Monat6	0.474625	0.048342	0.048362	9.814	< 2e-16	***
Monat7	0.374485	0.049358	0.049378	7.584	< 2e-16	***
Monat8	0.280835	0.048672	0.048693	5.767	< 2e-16	***
Monat9	0.273891	0.043979	0.043998	6.225	< 2e-16	***
Monat10	0.219709	0.038770	0.038787	5.665	< 2e-16	***
Monat11	0.017982	0.035559	0.035574	0.505	0.61323	
Monat12	-0.168035	0.033889	0.033903	4.956	7e-07	***
PhaseLockdown_1	0.566332	0.061172	0.061197	9.254	< 2e-16	***
PhaseInter	0.282667	0.045752	0.045771	6.176	< 2e-16	***
PhaseLockdown_2	0.456221	0.062628	0.062654	7.282	< 2e-16	***
PhasePost	0.148027	0.052636	0.052658	2.811	0.00494	**
rrel150j0_scaled	-0.143840	0.006924	0.006927	20.766	< 2e-16	***
sremadv_scaled	0.216378	0.008874	0.008878	24.372	< 2e-16	***
tre200jx_scaled	0.087202	0.016154	0.016160	5.396	1e-07	***
Wochentag2	0.048510	0.025141	0.025152	1.929	0.05377	.
Wochentag3	0.006901	0.025136	0.025147	0.274	0.78376	
Wochentag4	0.007289	0.025133	0.025144	0.290	0.77191	
Wochentag5	-0.014296	0.025122	0.025133	0.569	0.56948	
Wochentag6	0.495827	0.024867	0.024878	19.931	< 2e-16	***
Wochentag7	0.996292	0.024750	0.024760	40.237	< 2e-16	***
rrel150n0_scaled	-0.004586	0.007005	0.007008	0.654	0.51290	

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Multivariates Modell berechnen

Minimal adäquates Modell (negativ binomial)

```
# Funktion glmmTMB() aus library lme4 schneller
# Totale Besucheranzahl pro Tag durch abhängige Variablen erklären
# Tage bis Neujahr als "random factor"
# nicht signifikante Variable: rre150n0_scaled ausgeschlossen (Niederschlag Nacht)
# family: verschiedene Modelle für Datenverteilungen

nb_1 <- glmmTMB(Total ~ Monat + Ferien + Phase + Wochenende +
                 tre200jx_scaled + rre150j0_scaled +
                 sremaxdv_scaled +
                 (1 | Tage_bis_Neujahr),
                 family = nbinom1,
                 data = umwelt)

summary(nb_1) # Ergebnis des Modells
```

```
Family: nbinom1 ( log )
Formula:
Total ~ Monat + Ferien + Phase + Wochenende + tre200jx_scaled +
       rre150j0_scaled + sremaxdv_scaled + (1 | Tage_bis_Neujahr)
Data: umwelt

      AIC      BIC    logLik -2*log(L)  df.resid
29711.6  29849.0 -14832.8   29665.6     2876
```

Random effects:

Conditional model:

Groups	Name	Variance	Std.Dev.
Tage_bis_Neujahr	(Intercept)	0.001729	0.04158

Number of obs: 2899, groups: Tage_bis_Neujahr, 366

Dispersion parameter for nbinom1 family (): 16.5

Conditional model:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	4.067628	0.038186	106.52	< 2e-16 ***
Monat2	0.098663	0.041870	2.36	0.018453 *
Monat3	0.400787	0.041637	9.63	< 2e-16 ***
Monat4	0.505133	0.043631	11.58	< 2e-16 ***
Monat5	0.641773	0.047102	13.63	< 2e-16 ***
Monat6	0.469342	0.053635	8.75	< 2e-16 ***
Monat7	0.434835	0.054778	7.94	2.05e-15 ***
Monat8	0.294501	0.055312	5.32	1.01e-07 ***

```

Monat9          0.296628  0.050126   5.92 3.27e-09 ***
Monat10         0.271959  0.044932   6.05 1.42e-09 ***
Monat11         0.052394  0.044711   1.17 0.241259
Monat12        -0.171978  0.044744  -3.84 0.000121 ***
Ferien1         0.066198  0.020218   3.27 0.001060 **
PhaseLockdown_1 0.593032  0.037179  15.95 < 2e-16 ***
PhaseInter      0.355275  0.024311  14.61 < 2e-16 ***
PhaseLockdown_2 0.539142  0.048266  11.17 < 2e-16 ***
PhasePost       0.104826  0.015181   6.91 5.02e-12 ***
WochenendeWochenende 0.714979  0.013943  51.28 < 2e-16 ***
tre200jx_scaled 0.040566  0.016704   2.43 0.015158 *
rrel150j0_scaled -0.168800  0.012157 -13.88 < 2e-16 ***
sremaxdv_scaled 0.205774  0.009509  21.64 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```

# Monat 11 kann (technisch) und sollte (Interpretation) nicht ausgeschlossen
werden

```

Minimal adäquates Modell (negativ binomial) mit quadratischem Term (Temperatur)

```

# quadratischer Term: tre200jx_scaled quadriert (Temperatur Tag)->an sehr
heissen Tagen kommen weniger Besucher in den Wald

nb_quad <- glmmTMB(Total ~ Monat + Ferien + Phase + Wochenende +
tre200jx_scaled + I(tre200jx_scaled^2) + rrel150j0_scaled + sremaxdv_scaled
+
                    (1 | Tage_bis_Neujahr),
                    family = nbinom1,
                    data = umwelt)

summary(nb_quad)

```

```

Family: nbinom1 ( log )
Formula:
Total ~ Monat + Ferien + Phase + Wochenende + tre200jx_scaled +
      I(tre200jx_scaled^2) + rrel150j0_scaled + sremaxdv_scaled +
      (1 | Tage_bis_Neujahr)
Data: umwelt

      AIC      BIC    logLik -2*log(L)  df.resid
29615.2  29758.5 -14783.6   29567.2     2875

Random effects:

Conditional model:

```

```

Groups           Name          Variance Std.Dev.
Tage_bis_Neujahr (Intercept) 0.001161 0.03407
Number of obs: 2899, groups:  Tage_bis_Neujahr, 366

Dispersion parameter for nbinom1 family (): 16

Conditional model:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)    4.232014   0.040428 104.68 < 2e-16 ***
Monat2          0.019132   0.041693   0.46 0.646327
Monat3          0.272729   0.042394   6.43 1.25e-10 ***
Monat4          0.360251   0.044639   8.07 7.01e-16 ***
Monat5          0.511081   0.047269  10.81 < 2e-16 ***
Monat6          0.399028   0.052154   7.65 2.00e-14 ***
Monat7          0.387566   0.053022   7.31 2.68e-13 ***
Monat8          0.246059   0.053421   4.61 4.10e-06 ***
Monat9          0.172091   0.049934   3.45 0.000568 ***
Monat10         0.117159   0.046054   2.54 0.010960 *
Monat11        -0.033518   0.044300  -0.76 0.449282
Monat12        -0.189820   0.043735  -4.34 1.42e-05 ***
Ferien1         0.069139   0.019683   3.51 0.000444 ***
PhaseLockdown_1 0.584347   0.036575  15.98 < 2e-16 ***
PhaseInter      0.349245   0.023900  14.61 < 2e-16 ***
PhaseLockdown_2 0.569581   0.047534  11.98 < 2e-16 ***
PhasePost       0.105792   0.014946   7.08 1.46e-12 ***
WochenendeWochenende 0.715877   0.013700  52.25 < 2e-16 ***
tre200jx_scaled 0.062001   0.016879   3.67 0.000240 ***
I(tre200jx_scaled^2) -0.084621   0.008648  -9.78 < 2e-16 ***
rrel150j0_scaled -0.180231   0.012182 -14.79 < 2e-16 ***
sremaxdv_scaled 0.214563   0.009290  23.10 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

Interaktionen einzelner Variablen (Monat und Niederschlag)

```

nb_quad_inter <- glmmTMB(Total ~ Monat + Ferien + Phase + Wochenende +
tre200jx_scaled + I(tre200jx_scaled^2) + rrel150j0_scaled + sremaxdv_scaled
+
                        Monat * rrel150j0_scaled +
                        (1 | Tage_bis_Neujahr),
family =nbinom1,
data = umwelt)

summary(nb_quad_inter)

```

```

Family: nbinom1 ( log )
Formula:

```

```
Total ~ Monat + Ferien + Phase + Wochenende + tre200jx_scaled +
      I(tre200jx_scaled^2) + rre150j0_scaled + sremaxdv_scaled +
      Monat * rre150j0_scaled + (1 | Tage_bis_Neujahr)
```

Data: umwelt

AIC	BIC	logLik	-2*log(L)	df.resid
29587.8	29796.9	-14758.9	29517.8	2864

Random effects:

Conditional model:

Groups	Name	Variance	Std.Dev.
Tage_bis_Neujahr	(Intercept)	0.001129	0.03359

Number of obs: 2899, groups: Tage_bis_Neujahr, 366

Dispersion parameter for nbinom1 family (): 15.7

Conditional model:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	4.2038820	0.0408994	102.79	< 2e-16 ***
Monat2	0.0367710	0.0431922	0.85	0.394583
Monat3	0.2760229	0.0441746	6.25	4.15e-10 ***
Monat4	0.3507000	0.0463089	7.57	3.65e-14 ***
Monat5	0.5257191	0.0477816	11.00	< 2e-16 ***
Monat6	0.4265244	0.0525506	8.12	4.80e-16 ***
Monat7	0.4054221	0.0533537	7.60	2.99e-14 ***
Monat8	0.2662115	0.0536298	4.96	6.91e-07 ***
Monat9	0.1939516	0.0509511	3.81	0.000141 ***
Monat10	0.1304542	0.0471442	2.77	0.005655 **
Monat11	-0.0137950	0.0448325	-0.31	0.758310
Monat12	-0.1780975	0.0441302	-4.04	5.44e-05 ***
Ferien1	0.0701565	0.0195302	3.59	0.000328 ***
PhaseLockdown_1	0.5725021	0.0364433	15.71	< 2e-16 ***
PhaseInter	0.3479827	0.0237950	14.62	< 2e-16 ***
PhaseLockdown_2	0.5717008	0.0472796	12.09	< 2e-16 ***
PhasePost	0.1038827	0.0148463	7.00	2.61e-12 ***
WochenendeWochenende	0.7181159	0.0136105	52.76	< 2e-16 ***
tre200jx_scaled	0.0620858	0.0169741	3.66	0.000255 ***
I(tre200jx_scaled^2)	-0.0747986	0.0086901	-8.61	< 2e-16 ***
rre150j0_scaled	-0.2453179	0.0472461	-5.19	2.08e-07 ***
sremaxdv_scaled	0.2102211	0.0092361	22.76	< 2e-16 ***
Monat2:rre150j0_scaled	0.0601655	0.0706891	0.85	0.394698
Monat3:rre150j0_scaled	-0.0418380	0.0701295	-0.60	0.550787
Monat4:rre150j0_scaled	-0.0941427	0.0698363	-1.35	0.177643
Monat5:rre150j0_scaled	-0.0058091	0.0572468	-0.10	0.919174
Monat6:rre150j0_scaled	0.1416108	0.0564524	2.51	0.012124 *
Monat7:rre150j0_scaled	0.1163732	0.0533780	2.18	0.029245 *
Monat8:rre150j0_scaled	0.1589344	0.0516452	3.08	0.002088 **

```

Monat9:rrel150j0_scaled  0.0636287  0.0637185    1.00 0.317993
Monat10:rrel150j0_scaled -0.0008591  0.0633118   -0.01 0.989174
Monat11:rrel150j0_scaled  0.0816332  0.0625196    1.31 0.191648
Monat12:rrel150j0_scaled  0.0965158  0.0634983    1.52 0.128517
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```
# Niederschlag und Monat sind in den Sommermonaten Juni bis August signifikant
```

Interaktionen einzelner Variablen (Temperatur und Niederschlag)

```

nb_quad_inter1 <- glmmTMB(Total ~ Monat + Ferien + Phase + Wochenende +
tre200jx_scaled + I(tre200jx_scaled^2) + rrel150j0_scaled + sremaxdv_scaled
+
                        tre200jx_scaled * rrel150j0_scaled +
                        (1 | Tage_bis_Neujahr),
                        family =nbinom1,
                        data = umwelt)

summary(nb_quad_inter1)

```

```

Family: nbinom1 ( log )
Formula:
Total ~ Monat + Ferien + Phase + Wochenende + tre200jx_scaled +
      I(tre200jx_scaled^2) + rrel150j0_scaled + sremaxdv_scaled +
      tre200jx_scaled * rrel150j0_scaled + (1 | Tage_bis_Neujahr)
Data: umwelt

```

AIC	BIC	logLik	-2*log(L)	df.resid
29586.8	29736.1	-14768.4	29536.8	2874

Random effects:

Conditional model:

Groups	Name	Variance	Std.Dev.
Tage_bis_Neujahr	(Intercept)	0.001318	0.03631

Number of obs: 2899, groups: Tage_bis_Neujahr, 366

Dispersion parameter for nbinom1 family (): 15.7

Conditional model:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	4.231265	0.040364	104.83	< 2e-16 ***
Monat2	0.019075	0.041614	0.46	0.646684
Monat3	0.278029	0.042359	6.56	5.25e-11 ***
Monat4	0.367375	0.044659	8.23	< 2e-16 ***

```

Monat5            0.512246  0.047289  10.83 < 2e-16 ***
Monat6            0.390845  0.052099   7.50 6.29e-14 ***
Monat7            0.372767  0.053004   7.03 2.02e-12 ***
Monat8            0.236420  0.053347   4.43 9.35e-06 ***
Monat9            0.172608  0.049870   3.46 0.000538 ***
Monat10           0.121113  0.046008   2.63 0.008478 **
Monat11          -0.030250  0.044195  -0.68 0.493679
Monat12          -0.188467  0.043585  -4.32 1.53e-05 ***
Ferien1           0.069138  0.019626   3.52 0.000427 ***
PhaseLockdown_1   0.580391  0.036342  15.97 < 2e-16 ***
PhaseInter        0.346974  0.023749  14.61 < 2e-16 ***
PhaseLockdown_2   0.573331  0.047201  12.15 < 2e-16 ***
PhasePost         0.102779  0.014864   6.91 4.69e-12 ***
WochenendeWochenende 0.716242  0.013617  52.60 < 2e-16 ***
tre200jx_scaled   0.083122  0.017115   4.86 1.19e-06 ***
I(tre200jx_scaled^2) -0.078959  0.008609  -9.17 < 2e-16 ***
rrel150j0_scaled  -0.181735  0.011780 -15.43 < 2e-16 ***
sremaxdv_scaled   0.213856  0.009190  23.27 < 2e-16 ***
tre200jx_scaled:rrel150j0_scaled 0.077123  0.013422   5.75 9.14e-09 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```

```
# Temperatur und Niederschlag hochsignifikant
```

Interaktionen einzelner Variablen (Monat und Temperatur)

```

nb_quad_inter2 <- glmTMB(Total ~ Monat + Ferien + Phase + Wochenende +
tre200jx_scaled + I(tre200jx_scaled^2) + rrel150j0_scaled + sremaxdv_scaled
+
                        Monat * tre200jx_scaled +
                        (1 | Tage_bis_Neujahr),
                        family = nbinom1,
                        data = umwelt)

summary(nb_quad_inter2)

```

```

Family: nbinom1 ( log )
Formula:
Total ~ Monat + Ferien + Phase + Wochenende + tre200jx_scaled +
      I(tre200jx_scaled^2) + rrel150j0_scaled + sremaxdv_scaled +
      Monat * tre200jx_scaled + (1 | Tage_bis_Neujahr)
Data: umwelt

      AIC      BIC    logLik -2*log(L)  df.resid
29600.6  29809.6  -14765.3   29530.6     2864

```

Random effects:

Conditional model:

Groups Name Variance Std.Dev.
Tage_bis_Neujahr (Intercept) 0.002005 0.04478
Number of obs: 2899, groups: Tage_bis_Neujahr, 366

Dispersion parameter for nbinom1 family (): 15.7

Conditional model:

	Estimate	Std. Error	z	value	Pr(> z)
(Intercept)	4.037195	0.085765	47.07	< 2e-16	***
Monat2	0.159295	0.097401	1.64	0.101953	
Monat3	0.483203	0.091299	5.29	1.21e-07	***
Monat4	0.554918	0.090990	6.10	1.07e-09	***
Monat5	0.660509	0.090611	7.29	3.11e-13	***
Monat6	0.485348	0.098342	4.94	8.00e-07	***
Monat7	0.634879	0.103597	6.13	8.88e-10	***
Monat8	0.562111	0.099053	5.67	1.39e-08	***
Monat9	0.348571	0.094095	3.70	0.000212	***
Monat10	0.315171	0.090281	3.49	0.000481	***
Monat11	0.179092	0.101453	1.77	0.077519	.
Monat12	-0.176005	0.121935	-1.44	0.148899	
Ferien1	0.077817	0.020043	3.88	0.000103	***
PhaseLockdown_1	0.562253	0.037304	15.07	< 2e-16	***
PhaseInter	0.352910	0.023877	14.78	< 2e-16	***
PhaseLockdown_2	0.560082	0.047806	11.72	< 2e-16	***
PhasePost	0.105362	0.014945	7.05	1.79e-12	***
WochenendeWochenende	0.712976	0.013642	52.26	< 2e-16	***
tre200jx_scaled	-0.145523	0.081555	-1.78	0.074365	.
I(tre200jx_scaled^2)	-0.118578	0.022407	-5.29	1.21e-07	***
rrel150j0_scaled	-0.178362	0.012132	-14.70	< 2e-16	***
sremadv_scaled	0.212453	0.009321	22.79	< 2e-16	***
Monat2:tre200jx_scaled	0.095441	0.082351	1.16	0.246475	
Monat3:tre200jx_scaled	0.205335	0.084838	2.42	0.015507	*
Monat4:tre200jx_scaled	0.295452	0.092104	3.21	0.001338	**
Monat5:tre200jx_scaled	0.333026	0.106243	3.13	0.001721	**
Monat6:tre200jx_scaled	0.351527	0.128018	2.75	0.006034	**
Monat7:tre200jx_scaled	0.209855	0.134108	1.56	0.117626	
Monat8:tre200jx_scaled	0.149134	0.127150	1.17	0.240838	
Monat9:tre200jx_scaled	0.270502	0.113176	2.39	0.016843	*
Monat10:tre200jx_scaled	0.210786	0.099583	2.12	0.034286	*
Monat11:tre200jx_scaled	0.202014	0.094835	2.13	0.033159	*
Monat12:tre200jx_scaled	0.007602	0.096322	0.08	0.937095	


Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

```
# Temperatur und Monat: März, April, Mai, Juni, September, Oktober und
November signifikant
```

Test ZeroInflation (Residuen)

```
# dharma
simulationOutput1 <- simulateResiduals(fittedModel = nb_quad_inter, n = 1000)

testResiduals(simulationOutput1)
```



\$uniformity

Asymptotic one-sample Kolmogorov-Smirnov test

```
data: simulationOutput$scaledResiduals
D = 0.074657, p-value = 1.846e-14
alternative hypothesis: two-sided
```

\$dispersion

DHARMA nonparametric dispersion test via sd of residuals fitted vs. simulated

```
data: simulationOutput
dispersion = 1.6107, p-value < 2.2e-16
alternative hypothesis: two.sided
```

\$outliers

DHARMA outlier test based on exact binomial test with approximate expectations

```
data: simulationOutput
outliers at both margin(s) = 39, observations = 2899, p-value < 2.2e-16
alternative hypothesis: true probability of success is not equal to
0.001998002
95 percent confidence interval:
 0.009583357 0.018345103
sample estimates:
frequency of outliers (expected: 0.001998001998002 )
                                0.01345291
```

```
# ->zeroinflated Modell generieren
```

negativ Binomialmodell ZeroInflation (Residuen)

```
nb_zi <- glmmTMB(Total ~ Monat + Ferien + Phase + Wochenende + tre200jx_scaled
+ I(tre200jx_scaled^2)+rrel50j0_scaled + sremaxdv_scaled + (1|
Tage_bis_Neujahr),
                ziformula= ~1,
                family = nbinom2,
                data = umwelt)

# family nbinom1 oder nbinom2
# mit quadriertem Temperatur->bessere Modelle
# ziformula~1: single zero-inflation parameter applying to all observations

summary(nb_zi)
```

```
Family: nbinom2 ( log )
Formula:
Total ~ Monat + Ferien + Phase + Wochenende + tre200jx_scaled +
      I(tre200jx_scaled^2) + rrel50j0_scaled + sremaxdv_scaled +
      (1 | Tage_bis_Neujahr)
Zero inflation:      ~1
Data: umwelt

      AIC      BIC    logLik -2*log(L)  df.resid
29201.6  29350.9 -14575.8   29151.6     2874

Random effects:

Conditional model:
Groups          Name          Variance Std.Dev.
```

```

Tage_bis_Neujahr (Intercept) 0.008865 0.09415
Number of obs: 2899, groups: Tage_bis_Neujahr, 366

Dispersion parameter for nbinom2 family (): 7.95

Conditional model:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)    4.130937   0.039365  104.94 < 2e-16 ***
Monat2         0.027125   0.043245    0.63 0.530510
Monat3         0.298939   0.045384    6.59 4.49e-11 ***
Monat4         0.426537   0.048135    8.86 < 2e-16 ***
Monat5         0.607936   0.050468   12.05 < 2e-16 ***
Monat6         0.495483   0.055843    8.87 < 2e-16 ***
Monat7         0.421671   0.056530    7.46 8.70e-14 ***
Monat8         0.321032   0.055820    5.75 8.86e-09 ***
Monat9         0.237351   0.052254    4.54 5.57e-06 ***
Monat10        0.144590   0.048131    3.00 0.002664 **
Monat11       -0.035964   0.044333   -0.81 0.417237
Monat12       -0.180047   0.042194   -4.27 1.98e-05 ***
Ferien1        0.105456   0.022500    4.69 2.77e-06 ***
PhaseLockdown_1 0.618911   0.051307   12.06 < 2e-16 ***
PhaseInter     0.351100   0.027083   12.96 < 2e-16 ***
PhaseLockdown_2 0.589939   0.047532   12.41 < 2e-16 ***
PhasePost      0.117639   0.015146    7.77 8.04e-15 ***
WochenendeWochenende 0.768169   0.015365   50.00 < 2e-16 ***
tre200jx_scaled 0.062334   0.016866    3.70 0.000219 ***
I(tre200jx_scaled^2) -0.076999   0.008478   -9.08 < 2e-16 ***
rrel150j0_scaled -0.151836   0.007294  -20.82 < 2e-16 ***
sremaxdv_scaled 0.230550   0.009438   24.43 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Zero-inflation model:
              Estimate Std. Error z value Pr(>|z|)
(Intercept)   -21.38     817.29  -0.026   0.979

```

Transformationen

```

library("moments")
skewness(umwelt$Total)

```


```
[1] 2.079726
```

```

# Mit 2.08 ist die Verteilung deutlich rechtsschief. Die meisten Werte liegen
im unteren Bereich. Es gibt einige hohe Ausreißer, die den Mittelwert nach
rechts ziehen. Wenige sehr große Werte.

```

```
hist(umwelt$Total, breaks = 30, main = "Histogramm von Total", xlab = "Total")
```



```
# in glmm wird Transformation jedoch nicht empfohlen: Interpretation
# (Verzerren der Skalen) und Rücktransformation kompliziert. Nicht nötig gemäss
# Artikel-> Lo, Steson und Andrews, Sally (2015). To transform or not to
# transform: using generalized linear mixed models to analyse reaction time
# data. Frontiers in Psychology, August 2015|Volume 6|Article 1171

# The GLMM procedure allows researchers to select the dependent variable most
# appropriate to their research question rather than use a transformed dependent
# variable simply to meet mathematical assumptions
```

Modelle vergleichen (AIC)

```
mods <- list(nb_1 = nb_1, nb_quad = nb_quad, nb_zi = nb_zi,
             nb_quad_inter=nb_quad_inter, nb_quad_inter1=nb_quad_inter1,
             nb_quad_inter2=nb_quad_inter2)
AICcmodavg::aictab(mods)
```

Model selection based on AICc:

	K	AICc	Delta_AICc	AICcWt	Cum.Wt	LL
nb_zi	25	29202.02	0.00	1	1	-14575.79
nb_quad_inter1	25	29587.21	385.18	0	1	-14768.38
nb_quad_inter	35	29588.73	386.70	0	1	-14758.92
nb_quad_inter2	35	29601.49	399.47	0	1	-14765.31
nb_quad	24	29615.57	413.55	0	1	-14783.58
nb_1	23	29711.99	509.96	0	1	-14832.80

```
# Nur Modelle mit derselben abhängigen Variable können miteinander verglichen
werden. Keine logarithmierten oder exponentialen Daten. nb_gamma kann nicht in
Vergleich miteinbezogen werden, da logarithmiert und abhängige Variable "Total
+ 1"

# Der AIC für das zeroinflated Modell nb_zi ist am kleinsten (~0), dies ist
unser bestes Modell
```

Diagnostik des besten Modells (negativ binomial zeroinflated)

```
# Residuals über Simulation auf Standard-Skala transformiert und getestet
# Falls Faktoren, Überblick Signifikanz

car::Anova(nb_zi)
```

Analysis of Deviance Table (Type II Wald chisquare tests)

Response: Total


	Chisq	Df	Pr(>Chisq)	
Monat	394.222	11	< 2.2e-16	***
Ferien	21.966	1	2.775e-06	***
Phase	448.151	4	< 2.2e-16	***
Wochenende	2499.501	1	< 2.2e-16	***
tre200jx_scaled	13.659	1	0.0002192	***
I(tre200jx_scaled^2)	82.484	1	< 2.2e-16	***
rre150j0_scaled	433.346	1	< 2.2e-16	***
sremadv_scaled	596.740	1	< 2.2e-16	***

Signif. codes:	0	'***'	0.001	'**'
	0.01	'*'	0.05	'.'
	0.1	' '		1


```
# dharma
simulationOutput <- simulateResiduals(fittedModel = nb_zi, n = 1000)

# scaled residuals plotten und testen
plot(simulationOutput)
```

DHARMa residual



```
testResiduals(simulationOutput)
```



```
$uniformity
```

Asymptotic one-sample Kolmogorov-Smirnov test

```
data: simulationOutput$scaledResiduals
D = 0.056298, p-value = 2.09e-08
alternative hypothesis: two-sided
```

```
$dispersion
```

DHARMa nonparametric dispersion test via sd of residuals fitted vs. simulated


```
data: simulationOutput
dispersion = 1.1243, p-value = 0.05
alternative hypothesis: two.sided
```

```
$outliers
```

DHARMA outlier test based on exact binomial test with approximate expectations

```
data: simulationOutput
outliers at both margin(s) = 31, observations = 2899, p-value =
1.809e-13
alternative hypothesis: true probability of success is not equal to
0.001998002
95 percent confidence interval:
0.007276849 0.015144273
sample estimates:
frequency of outliers (expected: 0.001998001998002 )
0.01069334
```

```
# Zeroinflation
testZeroInflation(simulationOutput)
```



DHARMA zero-inflation test via comparison to expected zeros with simulation under H0 = fitted model

```
data: simulationOutput
```

```
ratioObsSim = 0, p-value = 1
alternative hypothesis: two.sided
```

```
# Testen auf Multicollinearität (stark korrelierte Variablen im Modell)
# car::vif(nb_zi) funktioniert nicht mit glmmTMB-Objekten. Es wird ein
lineares Modellobjekt (lm, glm) erwartet, bei dem eine Varianz-Kovarianzmatrix
der geschätzten Koeffizienten berechnet werden kann. glmmTMB-Modelle sind
komplexer: Es gibt mehrere Parameterblöcke (Conditional, Zero-Inflation,
Dispersion).
# VIF values: <5 ist gut->alle Werte unter 5

performance::check_collinearity(nb_zi)
```

```
# Check for Multicollinearity
```

```
* conditional component:
```

```
Low Correlation
```

	Term	VIF	VIF 95% CI	adj. VIF	Tolerance	Tolerance 95% CI
	Ferien	1.31	[1.26, 1.38]	1.15	0.76	[0.73, 0.79]
	Phase	1.19	[1.15, 1.25]	1.02	0.84	[0.80, 0.87]
	Wochenende	1.01	[1.00, 2.25]	1.00	0.99	[0.44, 1.00]
	tre200jx_scaled	4.34	[4.08, 4.63]	2.08	0.23	[0.22, 0.25]
	I(tre200jx_scaled^2)	1.34	[1.28, 1.41]	1.16	0.75	[0.71, 0.78]
	rrel50j0_scaled	1.14	[1.10, 1.20]	1.07	0.88	[0.83, 0.91]
	sremaxdv_scaled	1.70	[1.62, 1.79]	1.30	0.59	[0.56, 0.62]

```
Moderate Correlation
```

	Term	VIF	VIF 95% CI	adj. VIF	Tolerance	Tolerance 95% CI
	Monat	6.56	[6.14, 7.01]	1.09	0.15	[0.14, 0.16]

```
# erklärte Varianz: Marginal R2 = fixed effects (interessant), Conditional R2
= fixed effects und random effects
# beide sehr hoch
```

```
performance::r2(nb_zi)
```

```
# R2 for Mixed Models
```

```
Conditional R2: 0.979
Marginal R2: 0.956
```

Modellresultate (des besten Modells) exportieren

```
tab_model(nb_zi,
          transform = NULL, # plot estimates auf der linearen Skala
          show.se = TRUE) # Standardfehler zeigen
```

```
## Marginal R2: fixed effects (interessant), conditional R2: fixed effects
plus random effects.
```

Modellvisualisierung

```
# Formel für kontinuierliche Variablen
```

```
rescale_plot_num <- function(input_df, input_term, unscaled_var, scaled_var,
                             num_breaks, x_lab, y_lab, x_scaling, x_nk) {
  plot_id <- plot_model(input_df, type = "pred", terms = input_term,
    axis.title = "", title = "", color = "orangered")
  labels <- round(seq(floor(min(unscaled_var)), ceiling(max(unscaled_var)),
    length.out = num_breaks + 1) * x_scaling, x_nk)

  custom_breaks <- seq(min(scaled_var), max(scaled_var), by =
    ((max(scaled_var) - min(scaled_var)) / num_breaks))
  custom_limits <- c(min(scaled_var), max(scaled_var))

  plot_id <- plot_id +
    scale_x_continuous(breaks = custom_breaks, limits = custom_limits, labels
    = c(labels), labs(x = x_lab)) +
    scale_y_continuous(labs(y = y_lab), limits = c(0, 150)) +
    theme_classic(base_size = 20)

  return(plot_id)
}
```

```
# Formel für diskrete Variablen
```

```
rescale_plot_fac <- function(input_df, input_term, unscaled_var, scaled_var,
                              num_breaks, x_lab, y_lab, x_scaling, x_nk) {
  plot_id <- plot_model(input_df, type = "pred", terms = input_term,
    axis.title = "", title = "", color = "orangered")


  plot_id <- plot_id +
    scale_y_continuous(labs(y = y_lab), limits = c(0, 150)) +
    theme_classic(base_size = 20) +
    theme(axis.text.x = element_text(angle = 45, vjust = 1, hjust = 1))

  return(plot_id)
}
```

Visualisierung Zusammenhang Besuchende-Temperatur

```
input_df <- nb_zi
input_term <- "tre200jx_scaled [all]"
unscaled_var <- umwelt$tre200jx
scaled_var <- umwelt$tre200jx_scaled
num_breaks <- 10
x_lab <- "Temperatur [°C]"
y_lab <- "Fussgänger:innen pro Tag"
x_scaling <- 1 # in Prozent
x_nk <- 0 # x runde Nachkommastellen

p_temp <- rescale_plot_num(
  input_df, input_term, unscaled_var, scaled_var, num_breaks,
  x_lab, y_lab, x_scaling, x_nk
)
p_temp
```



Visualisierung Zusammenhang Besuchende-Niederschlag


```
input_df <- nb_zi
input_term <- "rre150j0_scaled [all]"
unscaled_var <- umwelt$rre150j0
scaled_var <- umwelt$rre150j0_scaled
num_breaks <- 10
x_lab <- "Niederschlag [mm]"
y_lab <- "Fussgänger:innen pro Tag"
x_scaling <- 1
x_nk <- 0

p_nsch <- rescale_plot_num(
```

```

    input_df, input_term, unscaled_var, scaled_var, num_breaks,
    x_lab, y_lab, x_scaling, x_nk
  )
p_nsch

```




Visualisierung Zusammenhang Besuchende-Sonnenscheindauer

```

input_df <- nb_zi
input_term <- "sremaxdv_scaled [all]"
unscaled_var <- umwelt$sremaxdv
scaled_var <- umwelt$sremaxdv_scaled
num_breaks <- 10
x_lab <- "Sonnenscheindauer [% relativ zur absolut möglichen Tagessumme]"
y_lab <- "Fussgänger:innen pro Tag"
x_scaling <- 1
x_nk <- 0

p_ss <- rescale_plot_num(
  input_df, input_term, unscaled_var, scaled_var, num_breaks,
  x_lab, y_lab, x_scaling, x_nk
)
p_ss


```



Visualisierung Besuchende und Werktag/Wochenende

```
input_df <- nb_zi
input_term <- "Wochenende [all]"
unscaled_var <- umwelt$Wochenende
scaled_var <- umwelt$Wochenende
num_breaks <- 10
x_lab <- "Wochentag"
y_lab <- "Fussgänger:innen pro Tag"
x_scaling <- 1
x_nk <- 0


p_wd <- rescale_plot_fac(
  input_df, input_term, unscaled_var, scaled_var, num_breaks,
  x_lab, y_lab, x_scaling, x_nk)
p_wd
```



Visualisierung Besuchende und Monat

```
input_df <- nb_zi
input_term <- "Monat [all]"
unscaled_var <- umwelt$Monat
scaled_var <- umwelt$Monat
num_breaks <- 10
x_lab <- "Monate"
y_lab <- "Fussgänger:innen pro Tag"
x_scaling <- 1
x_nk <- 0

p_mt <- rescale_plot_fac(
  input_df, input_term, unscaled_var, scaled_var, num_breaks,
  x_lab, y_lab, x_scaling, x_nk)
p_mt
```




Visualisierung Besuchende und Covidphase

```
input_df <- nb_zi
input_term <- "Phase [all]"
unscaled_var <- umwelt$Phase
scaled_var <- umwelt$Phase
num_breaks <- 10
x_lab <- "COVID-Phase"
y_lab <- "Fussgänger:innen pro Tag"
x_scaling <- 1
x_nk <- 0

p_cv <- rescale_plot_fac(
  input_df, input_term, unscaled_var, scaled_var, num_breaks,
```

```
x_lab, y_lab, x_scaling, x_nk)
p_cv
```



Visualisierung Besuchende und Ferien

```
input_df <- nb_zi
input_term <- "Ferien [all]"
unscaled_var <- umwelt$Ferien
scaled_var <- umwelt$Ferien
num_breaks <- 10
x_lab <- "Ferien"
y_lab <- "Fussgänger:innen pro Tag"
x_scaling <- 1
x_nk <- 0

p_fe <- rescale_plot_fac(
  input_df, input_term, unscaled_var, scaled_var, num_breaks,
  x_lab, y_lab, x_scaling, x_nk)
p_fe
```

