

Anhang zu: Birrer et al. (2015): Die Malser Haide – eine bewässerte Landschaft mit grosser Bedeutung für Wiesenbrüter. Der Ornithologische Beobachter 112: 269–282

In diesem Anhang wird die Modellselektion inkl. Schätzwerte zu den Modellen aufgelistet

1 Bezeichnung der Variablen und Abkürzungen

1.1 allgemeine Abkürzungen

MS = Manuskript bzw. Publikation im Ornithol. Beob.

1.2 Modelle zur Artenzahl

AZ = Artenzahl (alle Arten)
AZUZL = Zahl der Arten gemäss Umweltzielen Landwirtschaft
Di.Baeume = Baumdichte pro Stufe [n/ha]
Di.Hecke = Heckendichte pro Stufe [m/ha]
Fl.l = Fläche (der Höhenstufe): orthogonale Polynom, linear
Fl.c = orthogonales Polynom (kubisch) der Fläche
Fl.q = orthogonales Polynom (quadratisch) der Fläche
Fl_ha = Fläche einer Höhenstufe in Hektaren
HS.l = Mittlere Höhe einer Stufe (orthogonale Polynom, linear)
HS.q = orthogonales Polynom (quadratisch) der mittleren Höhe
int.lo = Anteil intensiv genutzte Fläche pro Höhenstufe (logit-transformiert)
mod1-8 = 8 Modelle Artenzahl pro Höhenstufe
modU1-U8 = 8 Modelle UZL-Artenzahl pro Höhenstufe
Reg.lo = Anteil Fläche einer Höhenstufe, die beregnet wird (logit-transformiert)

1.3 Modelle zu Revieren

Baum.f = Vorkommen von Bäumen im "Revier" (Faktor)
H.l = mittlere Höhe (Revierzentrum; orthogonales Polynom, linear)
H.q = quadratischer Term mittlere Höhe (Revierzentrum; orthogonales Polynom)
Hecke.f = Vorkommen von Hecken im "Revier" (Faktor)
Int.f = Vorkommen intensiv genutzter Flächen im "Revier" (Faktor)
ModB... = Modell Braunkehlchen mit unterschiedlichen spatial correlations
0: ohne, 1: corExp, 2: corGaus, 3: corRatio, 4: corLin, 5: corSpher
und einem zusätzlichen Faktor:
a: Int.f, b: Hecke.f, c: Baum.f
ModF... = Modell Feldlerche mit unterschiedlichen spatial correlations
ModN... = Modell Neuntöter mit unterschiedlichen spatial correlations
ModW... = Modell Wachtel mit unterschiedlichen spatial correlations
Reg.f = Vorkommen beregneter Flächen im "Revier" (Faktor)

2 Modelle Artenzahl ~ Höhenstufen

2.1 Abhängigkeit der Artenzahl von der Fläche

"Da die Flächen der Höhenstufen unterschiedlich gross waren, bauten wir die logarithmierte Fläche als Offset ein". Doch zuerst erstellten wir Modelle inkl. quadratischer und kubischer Fläche. Die kubische und quadratische Terme wurden anschliessend schrittweise entfernt, wenn sie nicht signifikant waren.

```
glm(AZ ~ Fl.l + Fl.q + Fl.c, family=quasipoisson, dat=HS)
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.3074      0.0777  29.695 2.72e-10 ***
Fl.l         0.8974      0.2304   3.896 0.00364 **
Fl.q         0.2016      0.2584   0.780 0.45526
Fl.c        -0.1560      0.2546  -0.613 0.55517
```

```
glm(AZ ~ Fl.l + Fl.q, family=quasipoisson, dat=HS)
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.30858      0.07492  30.815 3.04e-11 ***
Fl.l         0.89801      0.22434   4.003 0.00251 **
Fl.q         0.17563      0.24827   0.707 0.49545
```

```
glm(AZ ~ Fl.l + Fl.q, family=quasipoisson, dat=HS)
Deviance Residuals:
      Min       1Q   Median       3Q      Max
-1.8527  -0.1235   0.1305   0.2420   1.3920
```

```
Coefficients:
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  2.30773      0.07335  31.463 3.97e-12 ***
Fl.l         0.95216      0.21104   4.512 0.000884 ***
```

(Dispersion parameter for quasipoisson family taken to be 0.6829462)

```
Null deviance: 20.3381 on 12 degrees of freedom
Residual deviance: 7.9848 on 11 degrees of freedom
```

Number of Fisher Scoring iterations: 4

Der lineare Term erwies sich signifikant. Für die folgenden Modelle wurde deshalb ein Offset mit dem Logarithmus der Fläche eingefügt.

2.2 Abhängigkeit der Artenzahl

"Zunächst erstellten wir acht Modelle, bei denen die erklärenden Variablen «Anteil der intensiv genutzten Flächen» (logit-transformiert ...), Heckendichte sowie Baumdichte in allen möglichen Variationen vorkamen. Bei allen acht Modellen wurden zusätzlich die Faktoren «Anteil der berechneten Fläche» (logit-transformiert), «Höhenstufe» und «Höhenstufe im Quadrat» beigefügt, um nicht lineare Zusammenhänge erkennen zu können. Diese letzten drei Faktoren wurden in jedes Modell eingebaut, da wir vor allem am Einfluss der Berechnung interessiert sind und dieser mit der Höhenstufe korreliert. Die acht Modelle verglichen wir mit einem AIC ..."

Im Manuskript nicht erwähnt: zuerst auf Overdispersion geprüft:

```
glm(AZ ~ Reg.lo+HS.l+HS.q+int.lo+Di.Hecke+Di.Baeume, offset=log(Fl_ha),
family="quasipoisson", dat=HS))
```

```
Deviance Residuals:
      Min       1Q   Median       3Q      Max
-0.94246  -0.21372  -0.07795   0.57759   1.49286
```

```
Coefficients:
```

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-1.5690197	0.3465099	-4.528	0.00398 **
Reg.lo	0.0024088	0.0347253	0.069	0.94695
HS.l	0.3553011	1.1764453	0.302	0.77284
HS.q	-1.1266257	0.7333643	-1.536	0.17539
int.lo	0.0902606	0.0857174	1.053	0.33289
Di.Hecke	0.1190475	0.2724965	0.437	0.67748
Di.Baeume	0.0003395	0.0063120	0.054	0.95885

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

(Dispersion parameter for quasipoisson family taken to be 0.9440929)

Null deviance: 19.9003 on 12 degrees of freedom
Residual deviance: 5.1641 on 6 degrees of freedom
AIC: NA

Number of Fisher Scoring iterations: 4

Residual deviance ist fast gleich wie residual degree of freedom, d.h. es gibt keine overdispersion, deshalb verwenden wir im folgenden poisson-Modelle.

mod1 <- glm(AZ ~ Reg.lo+HS.l+HS.q+int.lo+Di.Hecke+Di.Baeume, offset=log(FI_ha), family="quasipoisson", dat=HS)

mod2: ohne Di.Baeume

mod3: ohne Di.Hecke

mod4: ohne int.lo

mod5: ohne Di.Baeume und ohne Di.Hecke

mod6: ohne Di.Baeume und ohne int.lo

mod7: ohne Di.Hecke und ohne int.lo

mod8: alle 3 ausgeschlossen

	df	AIC	Rang
mod1	7	72.9	
mod2	6	70.9	4
mod3	6	71.0	5
mod4	6	71.9	6
mod5	5	70.3	2
mod6	5	70.1	1
mod7	5	71.0	5
mod8	4	70.5	3

mod 6 hat den tiefsten AIC, allerdings sind alle anderen mit Ausnahme von mod 1 höchstens 2 Punkte schlechter, also ähnlich gut.

Mod 1:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-1.5690197	0.3566221	-4.400	1.08e-05 ***
Reg.lo	0.0024088	0.0357387	0.067	0.946
HS.l	0.3553011	1.2107776	0.293	0.769
HS.q	-1.1266257	0.7547661	-1.493	0.136
int.lo	0.0902606	0.0882189	1.023	0.306
Di.Hecke	0.1190475	0.2804488	0.424	0.671
Di.Baeume	0.0003395	0.0064962	0.052	0.958

Mod 2:

	Estimate	Std. Error	z value	Pr(> z)
(Intercept)	-1.571061	0.354611	-4.430	9.41e-06 ***
Reg.lo	0.002844	0.034752	0.082	0.9348
HS.l	0.303143	0.685426	0.442	0.6583
HS.q	-1.154895	0.526317	-2.194	0.0282 *
int.lo	0.088397	0.080742	1.095	0.2736
Di.Hecke	0.132563	0.108799	1.218	0.2231

Mod 3:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-1.5165091	0.3346711	-4.531	5.86e-06	***
Reg.lo	-0.0001081	0.0352963	-0.003	0.998	
HS.l	0.7853660	0.6677151	1.176	0.240	
HS.q	-0.9204422	0.5790735	-1.590	0.112	
int.lo	0.1079930	0.0776120	1.391	0.164	
Di.Baeume	0.0028792	0.0025633	1.123	0.261	

Mod 4:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-1.877e+00	1.919e-01	-9.779	<2e-16	***
Reg.lo	7.237e-05	3.518e-02	0.002	0.9984	
HS.l	-6.297e-01	7.377e-01	-0.854	0.3933	
HS.q	-1.383e+00	7.070e-01	-1.956	0.0505	.
Di.Hecke	2.585e-01	2.490e-01	1.038	0.2992	
Di.Baeume	-2.418e-03	5.948e-03	-0.407	0.6844	

Mod 5:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-1.29568	0.27362	-4.735	2.19e-06	***
Reg.lo	0.01006	0.03405	0.295	0.7677	
HS.l	0.58593	0.64150	0.913	0.3610	
HS.q	-1.19565	0.51982	-2.300	0.0214	*
int.lo	0.11666	0.07895	1.478	0.1395	

Mod 6:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-1.912404	0.172535	-11.084	<2e-16	***
Reg.lo	-0.003801	0.033836	-0.112	0.9106	
HS.l	-0.362389	0.339120	-1.069	0.2852	
HS.q	-1.188437	0.520130	-2.285	0.0223	*
Di.Hecke	0.166614	0.104292	1.598	0.1101	

Mod 7:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-1.895724	0.196246	-9.660	<2e-16	***
Reg.lo	-0.006867	0.034594	-0.199	0.8426	
HS.l	0.021001	0.399473	0.053	0.9581	
HS.q	-0.953433	0.571828	-1.667	0.0954	.
Di.Baeume	0.003162	0.002570	1.230	0.2186	

Mod 8:

	Estimate	Std. Error	z value	Pr(> z)	
(Intercept)	-1.685943	0.088727	-19.001	<2e-16	***
Reg.lo	0.005509	0.033094	0.166	0.8678	
HS.l	-0.248056	0.328203	-0.756	0.4498	
HS.q	-1.258667	0.509636	-2.470	0.0135	*

HS.q ist in den Modellen 2, 5, 6 und 8 signifikant (*). Diese 4 Modelle nehmen auch die Ränge 1-4 in der Reihenfolge der AIC ein. In den Modellen 4 und 7 ist HS.q tendenziell signifikant (gemäss AIC Plätze 5 und 6). Nicht signifikant erscheint es in den Modellen 1 und 3.

Von den übrigen Variablen wird keine je signifikant

2.3 Abhängigkeit der UZL-Artenzahl von der Fläche

Vorgehen wie 2.1, aber AZ jeweils durch AZUZL ersetzt

glm(AZUZL ~ Fl.l + Fl.q + Fl.c, family=quasipoisson, dat=HS)

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	1.73619	0.07946	21.849	4.16e-09	***
Fl.l	1.25696	0.22526	5.580	0.000343	***
Fl.q	0.18345	0.25910	0.708	0.496860	

```
Fl.c      -0.24876    0.24633   -1.010  0.338947
```

```
glm(AZUZL ~ Fl.l + Fl.q, family=quasipoisson, dat=HS)
```

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.73891    0.07811  22.263 7.51e-10 ***
Fl.l         1.26647    0.22574   5.610 0.000224 ***
Fl.q         0.12157    0.25195   0.483 0.639837
```

```
glm(AZUZL ~ Fl.l, family=quasipoisson, dat=HS)
```

```
Deviance Residuals:
    Min       1Q   Median       3Q      Max
-1.31077 -0.26294  0.04863  0.32610  0.99463
```

```
Coefficients:
```

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept)  1.73180    0.08317  20.824 1.45e-09 ***
Fl.l         1.23811    0.46858   2.642  0.0246 *
```

```
(Dispersion parameter for quasipoisson family taken to be 0.4315693)
```

```
Null deviance: 7.4723 on 11 degrees of freedom
Residual deviance: 4.5215 on 10 degrees of freedom
```

```
Number of Fisher Scoring iterations: 4
```

2.4 Abhängigkeit der UZL-Artenzahl

Vorgehen analog zu 2.2, aber AZ jeweils durch AZUZL ersetzt

Prüfung auf Overdispersion:

```
glm(AZUZL ~ Reg.lo+HS.l+HS.q+int.lo+Di.Hecke+Di.Baeume, offset=log(Fl_ha),
family="quasipoisson", dat=HS)
```

```
Deviance Residuals:
    Min       1Q   Median       3Q      Max
-1.03584 -0.21004 -0.00186  0.43376  0.94673
```

```
Coefficients:
```

```
      Estimate Std. Error t value Pr(>|t|)
(Intercept) -2.096073    0.323063  -6.488 0.000637 ***
Reg.lo       0.003096    0.036582   0.085 0.935313
HS.l         1.596352    1.173746   1.360 0.222695
HS.q        -0.465303    0.741789  -0.627 0.553587
int.lo       0.088635    0.080010   1.108 0.310374
Di.Hecke    -0.187099    0.281727  -0.664 0.531295
Di.Baeume    0.006111    0.006492   0.941 0.382859
```

```
(Dispersion parameter for quasipoisson family taken to be 0.5544536)
```

```
Null deviance: 8.1523 on 12 degrees of freedom
Residual deviance: 3.2786 on 6 degrees of freedom
AIC: NA
```

```
Number of Fisher Scoring iterations: 4
```

die Residual deviance ist kleiner als die degrees of freedom, dh. wir haben Underdispersion. da kann man nicht viel dagegen machen, aber man kann poisson-Modelle erstellen und ist damit konservativ, d.h. das Resultat wird eher nicht signifikant

```
      df  AIC Rang
modU1  7 63.78
modU2  6 62.27
modU3  6 62.02
```

```

modU4 6 62.46
modU5 5 60.41 2
modU6 5 60.60 4
modU7 5 60.47 3
modU8 4 58.83 1

```

hier gibt es mehr Unterschiede: modU8 ist das beste, modU5-7 nicht sehr viel schlechter. Deshalb im Folgenden nur die Modelle U5-U8

modU5

```

      Estimate Std. Error z value Pr(>|z|)
(Intercept) -2.02949    0.34317  -5.914 3.34e-09 ***
Reg.lo      0.01466    0.04614   0.318  0.751
HS.l       0.74997    0.80235   0.935  0.350
HS.q      -0.98416    0.69690  -1.412  0.158
int.lo     0.06267    0.09681   0.647  0.517

```

modU6

```

      Estimate Std. Error z value Pr(>|z|)
(Intercept) -2.336591    0.235822  -9.908 <2e-16 ***
Reg.lo      0.004931    0.046758   0.105  0.916
HS.l       0.254753    0.449430   0.567  0.571
HS.q      -0.938845    0.692951  -1.355  0.175
Di.Hecke   0.073274    0.152327   0.481  0.630

```

modU7

```

      Estimate Std. Error z value Pr(>|z|)
(Intercept) -2.377705    0.263237  -9.033 <2e-16 ***
Reg.lo      0.001158    0.047908   0.024  0.981
HS.l       0.484237    0.529831   0.914  0.361
HS.q      -0.762992    0.773707  -0.986  0.324
Di.Baeume  0.002105    0.003538   0.595  0.552

```

modU8

Deviance Residuals:

```

      Min      1Q      Median      3Q      Max
-0.81021 -0.39446 -0.08432  0.55164  0.95141

```

Coefficients:

```

      Estimate Std. Error z value Pr(>|z|)
(Intercept) -2.24026    0.11850 -18.905 <2e-16 ***
Reg.lo      0.01084    0.04507   0.241  0.810
HS.l       0.30862    0.43300   0.713  0.476
HS.q      -0.97231    0.68593  -1.418  0.156

```

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

(Dispersion parameter for poisson family taken to be 1)

```

Null deviance: 8.1523 on 12 degrees of freedom
Residual deviance: 4.3236 on 9 degrees of freedom
AIC: 58.825

```

Number of Fisher Scoring iterations: 4

3 Modelle Feldlerche

```
ModF0 <- gls(Anz ~ Reg.f+H.l+H.q, data=FEL, method="ML")
```

ModF1-5 dito, aber zusätzlich mit Term

```
ModF1: correlation=corExp(form=~KX+KY)
```

```
ModF2: correlation=corGaus(form=~KX+KY)
```

```
ModF3: correlation=corRatio(form=~KX+KY)
```

ModF4: correlation=corLin(form=~KX+KY)
 ModF5: correlation=corSpher(form=~KX+KY)

	df	AIC	Rang	Corr
ModF0	5	362.27		
ModF1	6	357.67		
ModF2	6	350.69	2	
ModF3	6	360.14		
ModF4	6	350.67	1	
ModF5	6	351.87	3	

Das Modell ohne spatial correlation ist das schlechteste, Delta AIC > 2 gegenüber dem nächstbesseren Modell

Weiter mit diesen beiden besten Modellen

```
> anova(ModF0, ModF2)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModF0	1	5	362.2739	379.8005	-176.1369			
ModF2	2	6	350.6855	371.7175	-169.3428	1 vs 2	13.58834	2e-04

```
> anova(ModF0, ModF4)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModF0	1	5	362.2739	379.8005	-176.1369			
ModF4	2	6	350.6688	371.7008	-169.3344	1 vs 2	13.60508	2e-04

ModF4 und ModF2 sind signifikant besser als ModF0

+ Faktor Int.f (ModF...a)

```
> anova(ModF2, ModF2a)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModF2	1	6	350.6855	371.7175	-169.3428			
ModF2a	2	7	352.0474	376.5847	-169.0237	1 vs 2	0.638139	0.4244

```
> anova(ModF4, ModF4a)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModF4	1	6	350.6688	371.7008	-169.3344			
ModF4a	2	7	352.1311	376.6685	-169.0656	1 vs 2	0.5376328	0.4634

Einbezug von Int.f ergibt keine Verbesserung des Modells!

+ Faktor Hecke.f (ModF...b)

```
> anova(ModF2, ModF2b)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModF2	1	6	350.6855	371.7175	-169.3428			
ModF2b	2	7	352.5038	377.0411	-169.2519	1 vs 2	0.1817492	0.6699

```
> anova(ModF4, ModF4b)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModF4	1	6	350.6688	371.7008	-169.3344			
ModF4b	2	7	352.4391	376.9764	-169.2195	1 vs 2	0.2297106	0.6317

Einbezug von Hecke.f ergibt keine Verbesserung des Modells!

+ Faktor Baum.f (ModF...c)

```
> anova(ModF2, ModF2c)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModF2	1	6	350.6855	371.7175	-169.3428			
ModF2c	2	7	351.5917	376.1290	-168.7958	1 vs 2	1.093856	0.2956

```
> anova(ModF4, ModF4c)
```

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModF4	1	6	350.6688	371.7008	-169.3344			
ModF4c	2	7	351.4866	376.0239	-168.7433	1 vs 2	1.182216	0.2769

Einbezug von Baum.f ergibt keine Verbesserung des Modells!

Es bleibt also bei ModF4

Generalized least squares fit by maximum likelihood

Model: Anz ~ Reg.f + H.l + H.q

Data: FEL

AIC	BIC	logLik
350.6688	371.7008	-169.3344

Correlation structure: Linear spatial correlation

Formula: ~KX + KY

Parameter estimate(s):

range
0.1512504

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	0.3673082	0.0563140	6.522501	0.0000
Reg.f1	0.1302036	0.0756480	1.721178	0.0865
H.l	0.1260634	0.5331039	0.236471	0.8133
H.q	-0.7299085	0.5596794	-1.304155	0.1934

Correlation:

	(Intr)	Reg.f1	H.l
Reg.f1	-0.812		
H.l	0.249	-0.294	
H.q	0.322	-0.409	0.133

Standardized residuals:

Min	Q1	Med	Q3	Max
-1.0784839	-0.8990567	-0.5272019	1.0836289	1.5336472

Residual standard error: 0.4861747

Degrees of freedom: 246 total; 242 residual

Tendenz von Reg.f (p=0,0865)

4 Modelle Braunkehlchen

ModB0 <- gls(Anz ~ Reg.f+H.l+H.q, data=FEL, method="ML")

ModB1-5 entsprechend ModF1-5

ModB4 konvergiert nicht! (im MS nicht erwähnt!)

	df	AIC	Rang
ModB0	5	187.04	
ModB1	6	185.23	3
ModB2	6	184.72	2
ModB3	6	184.44	1
ModB5	6	185.93	4

Das Modell ohne spatial correlation ist das schlechteste

Weiter mit diesen beiden besten Modellen

> anova(ModB0,ModB2)

Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModB0	1	5	187.0386	203.3000	-88.51931		
ModB2	2	6	184.7176	204.2313	-86.35881	1 vs 2	4.320997 0.0376

> anova(ModB0,ModB3)

Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModB0	1	5	187.0386	203.3000	-88.51931		
ModB3	2	6	184.4442	203.9578	-86.22209	1 vs 2	4.594449 0.0321

ModB2 und ModB3 sind signifikant besser als ModB0

+ Faktor Int.f (ModB...a)

> anova(ModB2, ModB2a)

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModB2	1	6	184.7176	204.2313	-86.35881			
ModB2a	2	7	185.8988	208.6647	-85.94939	1 vs 2	0.8188476	0.3655

> anova(ModB3, ModB3a)

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModB3	1	6	184.4442	203.9578	-86.22209			
ModB3a	2	7	185.6676	208.4335	-85.83382	1 vs 2	0.7765338	0.3782

Einbezug von Int.f ergibt keine Verbesserung des Modells!

+ Faktor Hecke.f (ModB...b)

> anova(ModB2, ModB2b)

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModB2	1	6	184.7176	204.2313	-86.35881			
ModB2b	2	7	185.1192	207.8851	-85.55959	1 vs 2	1.598441	0.2061

> anova(ModB3, ModB3b) # Hecke bringt wenig...

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModB3	1	6	184.4442	203.9578	-86.22209			
ModB3b	2	7	184.7937	207.5597	-85.39687	1 vs 2	1.650432	0.1989

Einbezug von Hecke.f ergibt keine Verbesserung des Modells!

+ Faktor Baum.f (ModB...c)

> anova(ModB2, ModB2c)

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModB2	1	6	184.7176	204.2313	-86.35881			
ModB2c	2	7	186.1817	208.9476	-86.09086	1 vs 2	0.535899	0.4641

> anova(ModB3, ModB3c) # Baum bringt nichts

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModB3	1	6	184.4442	203.9578	-86.22209			
ModB3c	2	7	185.9257	208.6916	-85.96284	1 vs 2	0.5184898	0.4715

Einbezug von Baum.f ergibt keine Verbesserung des Modells!

Es bleibt also bei ModB3

Generalized least squares fit by maximum likelihood

Model: Anz ~ Reg.f + H.l + H.q

Data: BRK

	AIC	BIC	logLik
	184.4442	203.9578	-86.22209

Correlation Structure: Rational quadratic spatial correlation

Formula: ~KX + KY

Parameter estimate(s):

range
0.05036403

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	0.0819216	0.0571738	1.4328526	0.1536
Reg.f1	0.2007812	0.0750092	2.6767523	0.0081
H.l	0.9324015	0.4983464	1.8709908	0.0629
H.q	0.3510577	0.5018137	0.6995776	0.4851

Correlation:

	(Intr)	Reg.f1	H.l
Reg.f1	-0.787		
H.l	0.278	-0.304	
H.q	0.319	-0.407	0.169

Standardized residuals:

	Min	Q1	Med	Q3	Max
--	-----	----	-----	----	-----

```
-1.13019913 -0.85449925 -0.21846835 -0.01250228 2.60598332
```

```
Residual standard error: 0.3822081  
Degrees of freedom: 191 total; 187 residual
```

Reg.f also significant, zur Sicherheit auch ModB2 kontrollieren:

```
Coefficients:  
              Value Std. Error  t-value p-value  
(Intercept) 0.0839229 0.0507931 1.6522497 0.1002  
Reg.f1       0.1917231 0.0685335 2.7975083 0.0057  
H.l         0.8518882 0.4238915 2.0096847 0.0459  
H.q         0.3173548 0.4460747 0.7114387 0.4777
```

und wie sieht das ohne spatial corr aus dafür mit binomial (im MS nicht erwähnt!):

```
summary(glm(Anz ~ Reg.f+H.l+H.q, data=BRK, family="binomial"))
```

```
Coefficients:  
              Estimate Std. Error z value Pr(>|z|)  
(Intercept) -2.6978      0.5394  -5.001 5.7e-07 ***  
Reg.f1       1.7721      0.6152   2.880 0.00397 **  
H.l          5.2835      2.7820   1.899 0.05755 .  
H.q          1.3217      3.5356   0.374 0.70853
```

Reg.f bleibt signifikant

5 Modelle Neuntöter

```
ModB0 <- gls(Anz ~ Reg.f+H.l+H.q, data=FEL, method="ML")
```

ModB1-5 ModB1-5 entsprechend ModF1-5

	df	AIC	Rang
ModN0	5	190.65	
ModN1	6	190.19	
ModN2	6	188.00	2
ModN3	6	191.14	
ModN4	6	187.16	1
ModN5	6	188.76	3

Hier ist das Modell ohne spatial correlation nicht das schlechteste, aber doch schlechter als die besten Modelle.

Weiter mit diesen beiden besten Modellen

```
> anova(ModN0, ModN2)  
      Model df      AIC      BIC    logLik  Test  L.Ratio p-value  
ModN0     1   5 190.6458 206.8013 -90.32289  
ModN2     2   6 188.0044 207.3910 -88.00218 1 vs 2 4.641405 0.0312
```

```
> anova(ModN0, ModN4)  
      Model df      AIC      BIC    logLik  Test  L.Ratio p-value  
ModN0     1   5 190.6458 206.8013 -90.32289  
ModN4     2   6 187.1559 206.5425 -87.57794 1 vs 2 5.489901 0.0191
```

ModB2 und ModN4 sind signifikant besser als ModN0

+ Faktor Int.f (ModN...a)

```
> anova(ModN2, ModN2a)  
      Model df      AIC      BIC    logLik  Test  L.Ratio p-value  
ModN2     1   6 188.0044 207.3910 -88.00218  
ModN2a    2   7 189.9329 212.5506 -87.96644 1 vs 2 0.07149321 0.7892
```

```
> anova(ModN4, ModN4a) # Int bringt nichts  
      Model df      AIC      BIC    logLik  Test  L.Ratio p-value  
ModN4     1   6 187.1559 206.5425 -87.57794  
ModN4a    2   7 189.0958 211.7135 -87.54789 1 vs 2 0.06009847 0.8063
```

Einbezug von Int.f ergibt keine Verbesserung des Modells!

+ Faktor Hecke.f (ModN...b)

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModN2	1	6	188.0044	207.3910	-88.00218			
ModN2b	2	7	177.1285	199.7463	-81.56425	1 vs 2	12.87586	3e-04

> `anova(ModN4, ModN4b)` # Hecke hoch signifikant

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModN4	1	6	187.1559	206.5425	-87.57794			
ModN4b	2	7	175.4184	198.0362	-80.70920	1 vs 2	13.73747	2e-04

Hecke.f verbessert Modell in beiden Fällen signifikant!

+ Faktor Hecke.f (ModN...b)

> `anova(ModN2, ModN2c)`

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModN2	1	6	188.0044	207.3910	-88.00218			
ModN2c	2	7	179.9094	202.5272	-82.95473	1 vs 2	10.09491	0.0015

> `anova(ModN4, ModN4c)` # Baum signifikant

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModN4	1	6	187.1559	206.5425	-87.57794			
ModN4c	2	7	178.3659	200.9836	-82.18294	1 vs 2	10.78999	0.001

Einbezug von Baum.f verbessert Modelle ebenfalls (aber weniger als Hecke.f)

... deshalb Hecke.f und Baum.f in Modell: ModN...bc

> `anova(ModN2b, ModN2bc)`

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModN2b	1	7	177.1285	199.7463	-81.56425			
ModN2bc	2	8	175.2323	201.0812	-79.61614	1 vs 2	3.896216	0.0484

> `anova(ModN4b, ModN4bc)` # Baum immer noch knapp signifikant

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModN4b	1	7	175.4184	198.0362	-80.70920			
ModN4bc	2	8	173.5028	199.3517	-78.75139	1 vs 2	3.915614	0.0478

ModN...bc ist signifikant besser als ModN...b

> `anova(ModN2c, ModN2bc)`

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModN2c	1	7	179.9094	202.5272	-82.95473			
ModN2bc	2	8	175.2323	201.0812	-79.61614	1 vs 2	6.677167	0.0098

> `anova(ModN4c, ModN4bc)`

	Model	df	AIC	BIC	logLik	Test	L.Ratio	p-value
ModN4c	1	7	178.3659	200.9836	-82.18294			
ModN4bc	2	8	173.5028	199.3517	-78.75139	1 vs 2	6.863098	0.0088

das gilt auch für Vergleich ModN...bc mit ModN...c

das beste Modell also ModN4bc:

Generalized least squares fit by maximum likelihood

Model: Anz ~ Reg.f + H.l + H.q + Hecke.f + Baum.f

Data: NEU

	AIC	BIC	logLik
	173.5028	199.3517	-78.75139

Correlation Structure: Linear spatial correlation

Formula: ~KX + KY

Parameter estimate(s):

range
0.1224857

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	0.1198299	0.0511152	2.3443109	0.0201
Reg.f1	-0.0273481	0.0642479	-0.4256651	0.6709
H.l	0.5755218	0.3946328	1.4583728	0.1465
H.q	-0.2716809	0.4353178	-0.6240979	0.5333

```
Hecke.f1 0.1806149 0.0692645 2.6076114 0.0099
Baum.f1 0.1379423 0.0704587 1.9577740 0.0518
```

```
Correlation:
      (Intr) Reg.f1 H.l H.q Hck.f1
Reg.f1 -0.734
H.l 0.159 -0.270
H.q 0.205 -0.425 0.149
Hecke.f1 -0.193 -0.004 -0.054 0.040
Baum.f1 -0.238 -0.013 0.150 0.231 -0.419
```

```
Standardized residuals:
      Min Q1 Med Q3 Max
-1.284571846 -0.421242745 -0.341032915 -0.003098525 2.414821370
```

```
Residual standard error: 0.3690375
Degrees of freedom: 187 total; 181 residual
```

6 Modelle Wachtel

```
ModW0 <- gls(Anz ~ Reg.f+H.l+H.q, data=FEL, method="ML")
ModW1-5 ModB1-5 entsprechend ModF1-5
```

```
df AIC
Modw0 5 101.57
Modw1 6 103.57
Modw2 6 103.57
Modw3 6 103.57
Modw4 6 103.57
Modw5 6 103.57
```

Hier ist das Modell ohne spatial correlation das (significant) beste. Deshalb weiter ohne spatial correlation:

```
+ Faktor Int.f (ModW0a)
> anova(Modw0, Modw0a) # Int bringt nichts
      Model df AIC BIC logLik Test L.Ratio p-value
Modw0 1 5 101.5673 117.2463 -45.78365
Modw0a 2 6 103.5244 122.3392 -45.76220 1 vs 2 0.0428882 0.8359
Einbezug von Int.f ergibt keine Verbesserung des Modells!
```

```
+ Faktor Hecke.f (ModW0b)
> anova(Modw0, Modw0b) # Hecke bringt wenig
      Model df AIC BIC logLik Test L.Ratio p-value
Modw0 1 5 101.5673 117.2463 -45.78365
Modw0b 2 6 101.9662 120.7810 -44.98309 1 vs 2 1.601122 0.2057
Einbezug von Hecke.f ergibt keine Verbesserung des Modells!
```

```
+ Faktor Baum.f (ModW0c)
> anova(Modw0, Modw0c) # Baum bringt nichts
      Model df AIC BIC logLik Test L.Ratio p-value
Modw0 1 5 101.5673 117.2463 -45.78365
Modw0c 2 6 102.3851 121.1999 -45.19257 1 vs 2 1.182152 0.2769
Einbezug von Baum.f ergibt keine Verbesserung des Modells!
```

```
Es bleibt also bei ModW0 Generalized least squares fit by maximum likelihood
      Model: Anz ~ Reg.f + H.l + H.q
      Data: WAC
      AIC BIC logLik
```

103.5673 122.3821 -45.78365

Correlation Structure: Rational quadratic spatial correlation

Formula: $\sim KX + KY$

Parameter estimate(s):

range
6.818531e-06

Coefficients:

	Value	Std.Error	t-value	p-value
(Intercept)	0.0667551	0.0424812	1.571401	0.1180
Reg.f1	0.0839965	0.0571800	1.468983	0.1437
H.1	0.4210660	0.3331515	1.263888	0.2080
H.q	-0.4637827	0.3528270	-1.314476	0.1905

Correlation:

	(Intr)	Reg.f1	H.1
Reg.f1	-0.816		
H.1	0.222	-0.272	
H.q	0.341	-0.418	0.114

Standardized residuals:

	Min	Q1	Med	Q3	Max
	-0.6166770	-0.4774838	-0.3543019	-0.2642514	2.8627856

Residual standard error: 0.3167562

Degrees of freedom: 170 total; 166 residual

Nichts signifikant