

2. Evaluation Prädiktiver Modelle mit Resampling

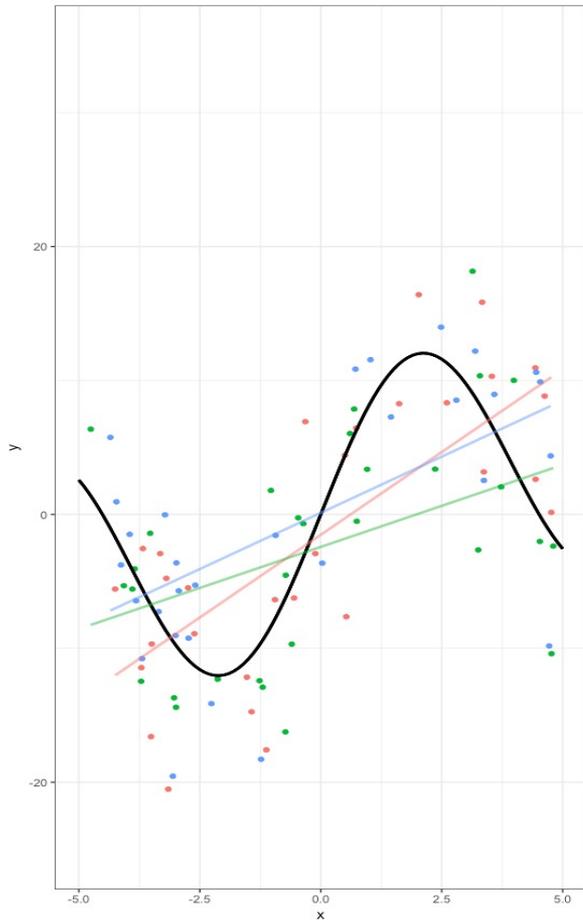


We are happy to share our materials openly:

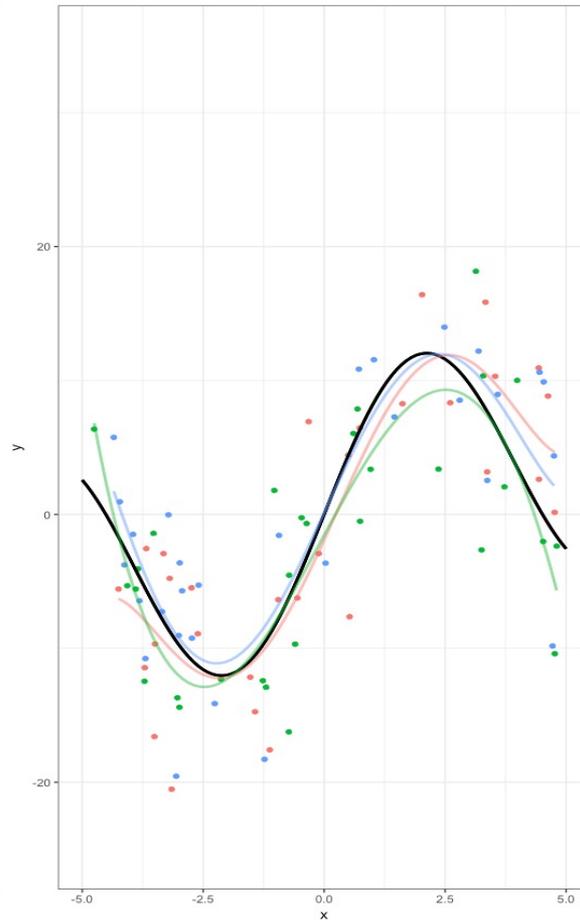
The content of these [Open Educational Resources](#) by [Lehrstuhl für Psychologische Methodenlehre und Diagnostik, Ludwig-Maximilians-Universität München](#) is licensed under [CC BY-SA 4.0](#). The CC Attribution-ShareAlike 4.0 International license means that you can reuse or transform the content of our materials for any purpose as long as you cite our original materials and share your derivatives under the same license.

Agenda für heute

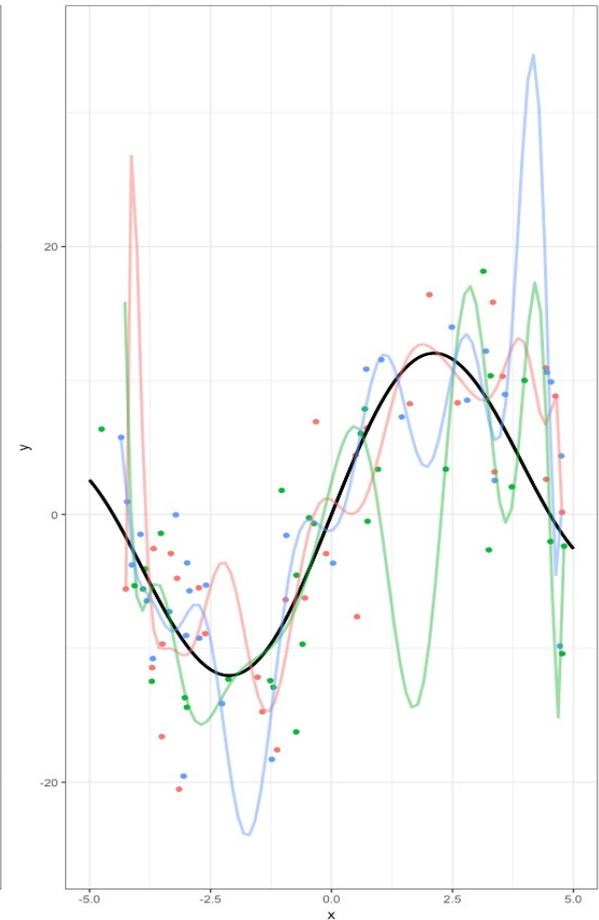
- Overfitting
- Bias-Varianz Tradeoff (Wdh.)
- Resampling
 - Grundprinzipien
 - Holdout
 - Negatives R^2
 - Kreuzvalidierung



zu einfach



angemessene
Komplexität



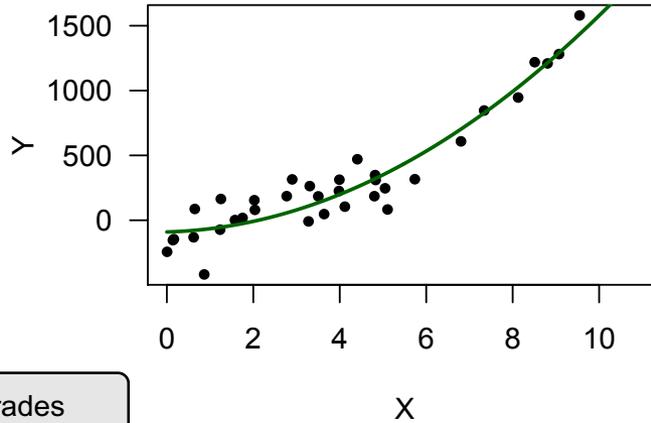
zu komplex

Schwarze Linie = wahrer Zusammenhang

- **Beobachtung:** Manche trainierten prädiktiven Modelle beschreiben eine konkrete Stichprobe gut
 - d.h. gute Vorhersagen für diejenigen Beobachtungen, die auch zur Schätzung der Modellparameter verwendet wurden („in-sample“) ...
 - ... aber ohne den wahren Zusammenhang in der Population richtig abzubilden
 - → schlechte Vorhersagen für *neue* Daten („out-of-sample“).
- Ist dieses Phänomen besonders ausgeprägt, spricht man von „Overfitting“
 - Der zufällige, nicht reduzierbare Fehler (das „Rauschen“) wird fälschlicherweise mitmodelliert
 - Das Modell passt sich den Daten zu stark an, es „lernt auswendig“
 - Das prädiktive Modell „halluziniert“ Muster in den Daten, die in der Realität gar nicht existieren
- Overfitting ist schlimmer ...
 - je größer der nicht reduzierbare Fehler
 - je kleiner die Stichprobe im Training
 - je flexibler die Modellklasse

Trainingsset

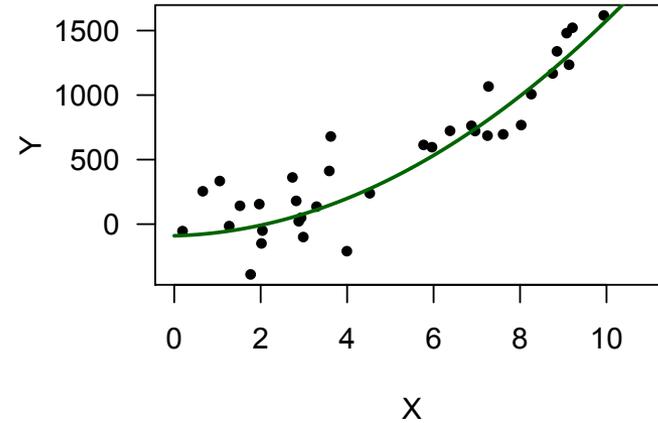
$R^2 = 0.91$; AICc = 452.63



$$y_i = b_0 + b_1x_i + b_2x_i^2 + \epsilon_i$$

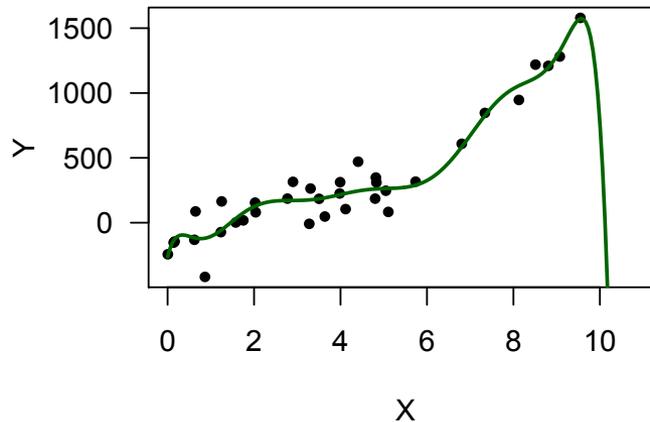
Testset

$R^2 = 0.85$; AICc = 480.87



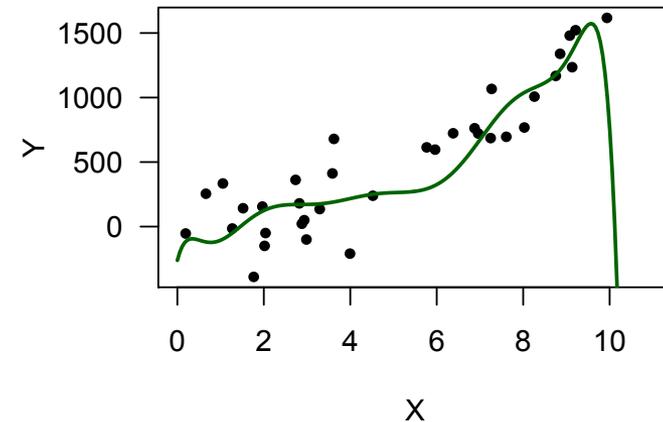
Polynom 10. Grades

$R^2 = 0.94$; AICc = 466.34

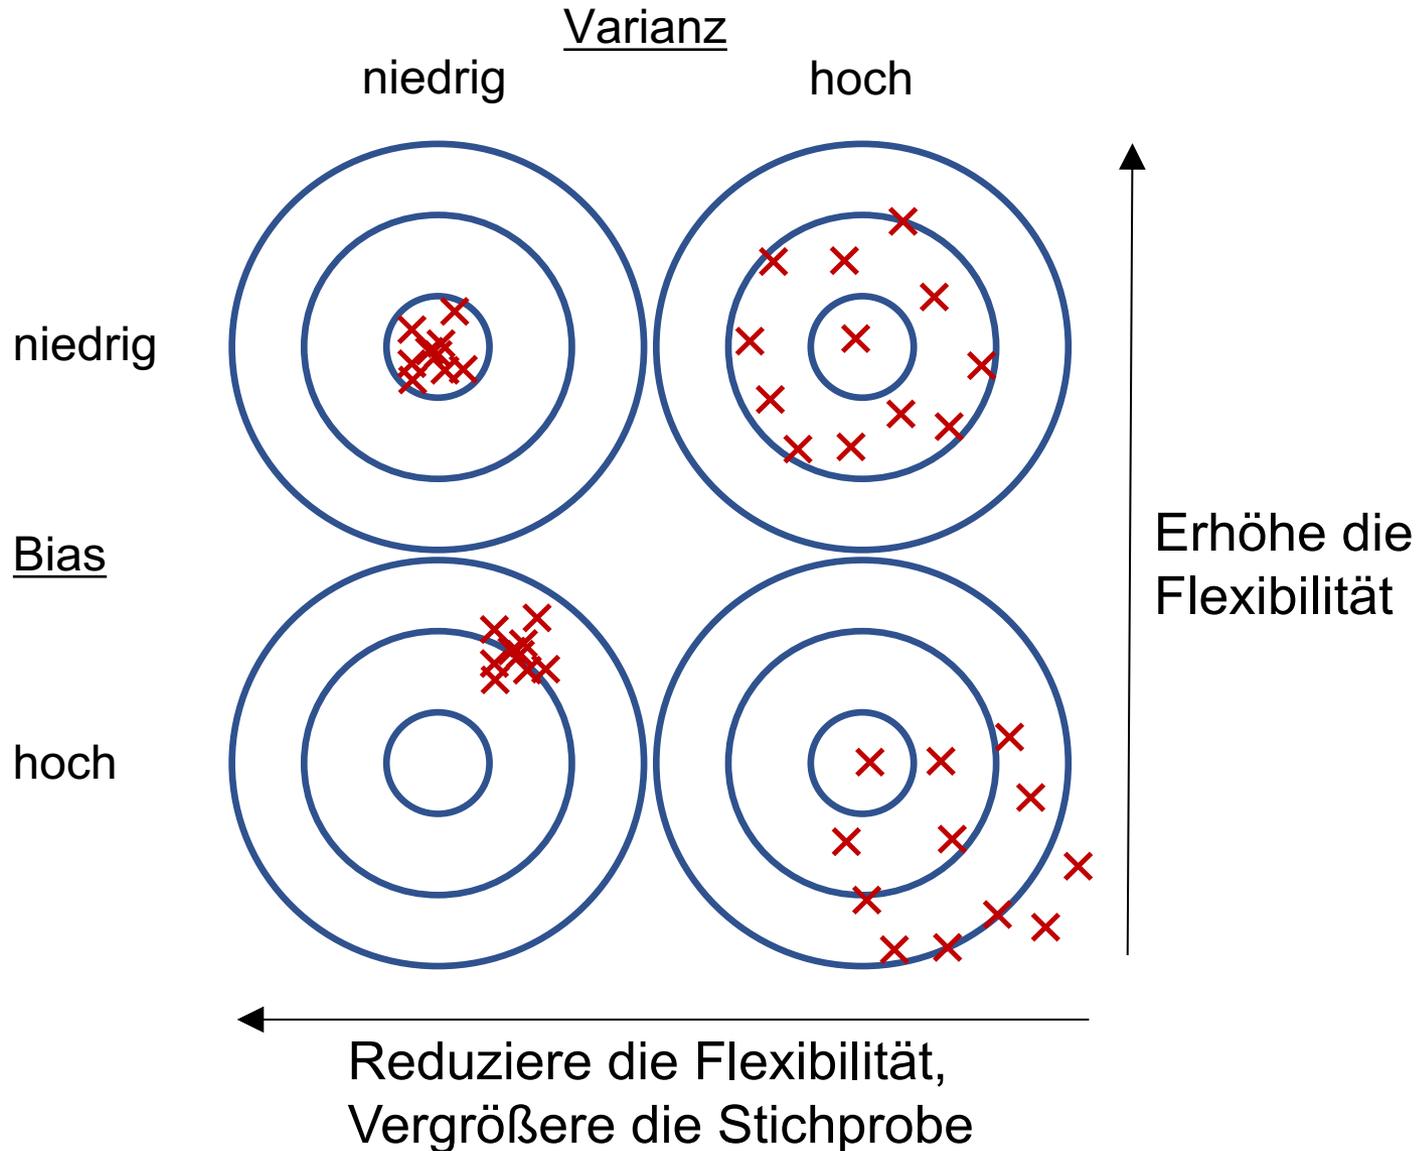


$$y_i = b_0 + b_1x_i + b_2x_i^2 + b_3x_i^3 + b_4x_i^4 + b_5x_i^5 + \dots + b_{10}x_i^{10} + \epsilon_i$$

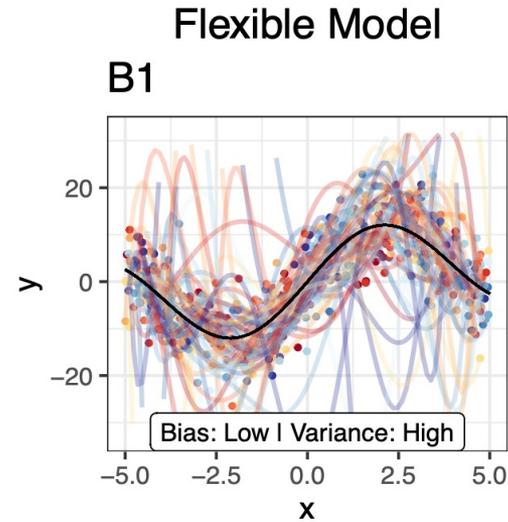
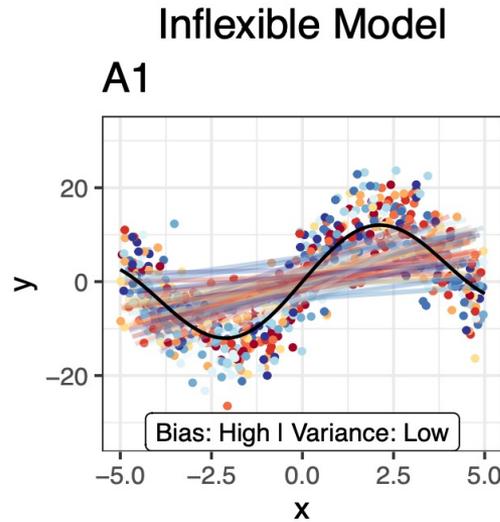
$R^2 = 0.78$; AICc = 524.43



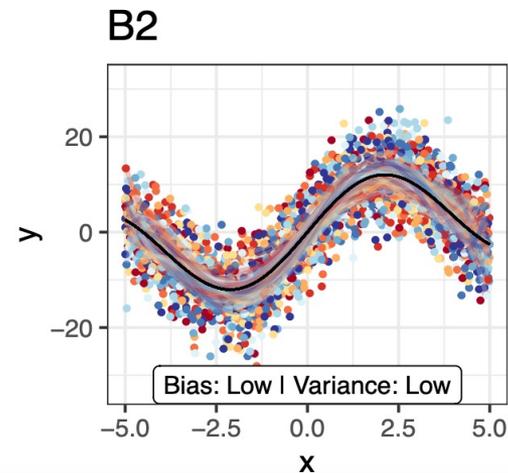
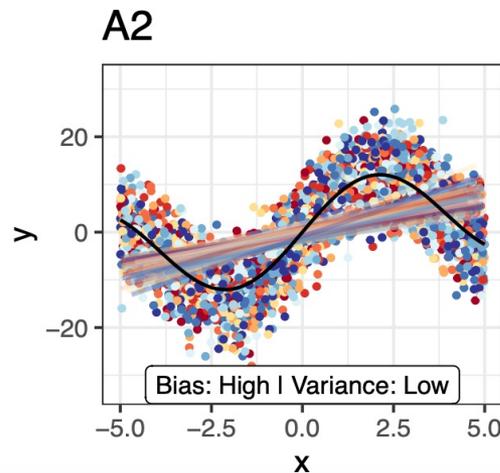
Wiederholung: Bias & Varianz



Example 1:
N = 12



Example 2:
N = 50

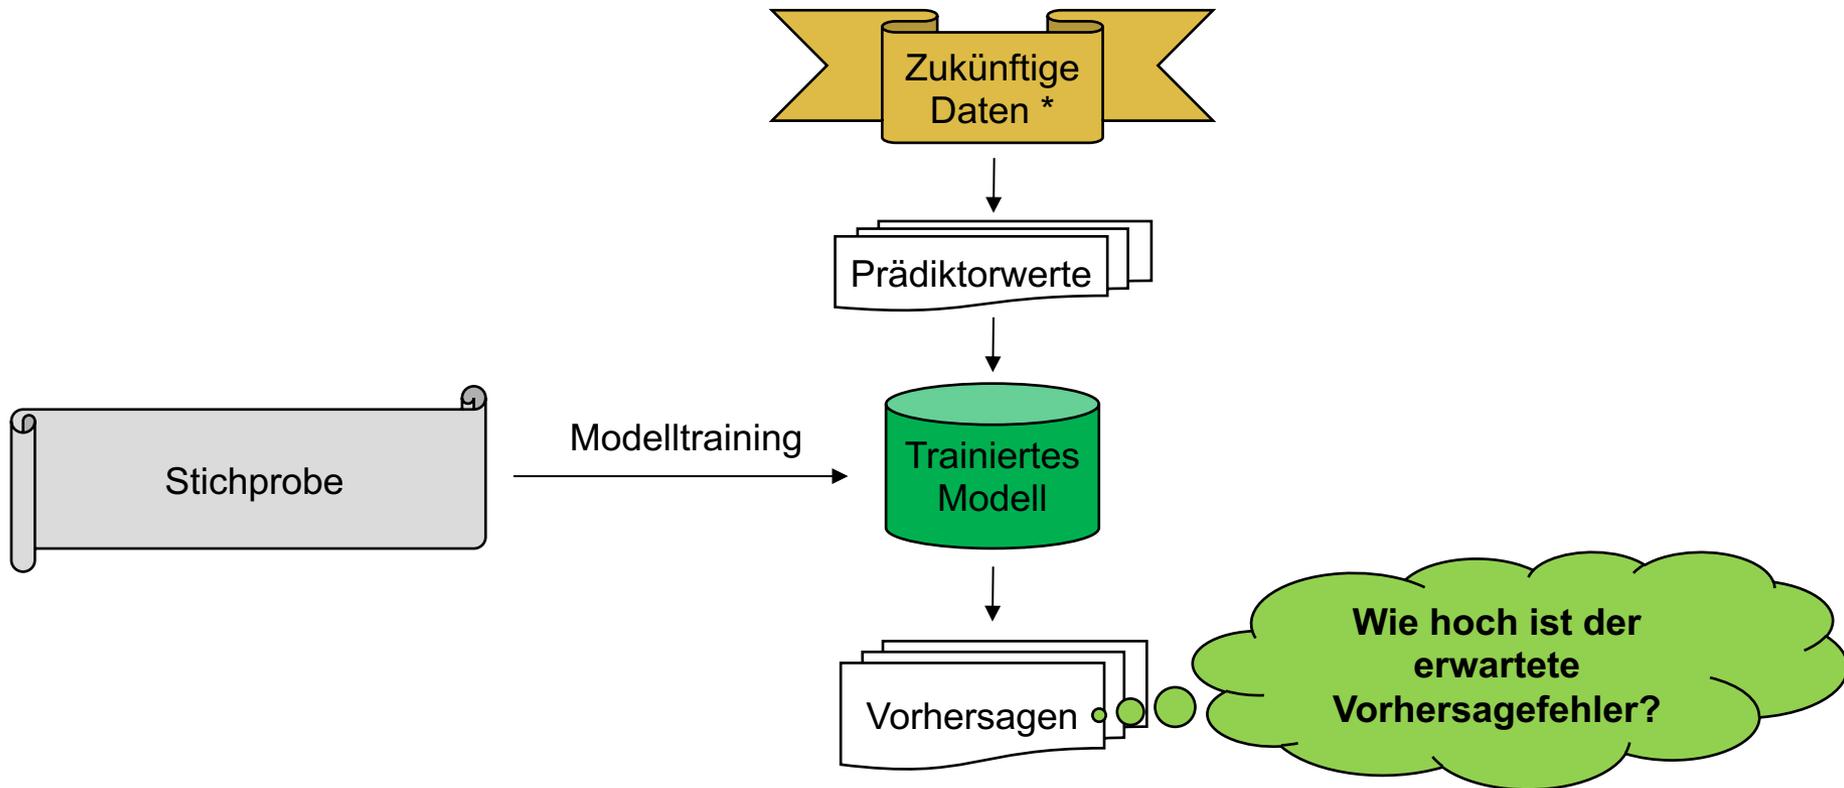


Bei B1 sehen wir das Overfitting

- Insbesondere bei komplexen (=flexiblen) Modellen und/oder kleinen Stichproben fangen die Modelle an, das Rauschen in dieser konkreten Stichprobe abzubilden.
 - Diese zufälligen Schwankungen werden sich in der nächsten Stichprobe nicht mehr finden – uns interessiert nur das systematische Signal, das in allen Stichproben vorhanden ist.
- Wir können Performancemaßen nicht trauen, die auf dem Trainingsdatensatz berechnet wurden („in-sample): Sie werden, gerade bei komplexen Modellen, stark überschätzt sein.
 - Hinweis: Bei der „klassischen“ Statistik machen wir aber genau das – z.B. das R^2 für Regressionsmodell *im Trainingsdatensatz* berechnen.
- Sobald ich das einmal trainierte Prädiktionsmodell auf *neue* Daten anwende, wird die Vorhersageperformance schlechter sein.
- Wie kommt man nun zu einer Abschätzung des Vorhersagefehlers für *neue* Daten?

- Wie genau sind die Vorhersagen des Modells bei *neuen* Beobachtungen?
→ **Ziel:** Schätzung des erwarteten Vorhersagefehlers
 - **Utopisches Vorgehen:** Erhebe zusätzliche Beobachtungen aus der Population (Prädiktorwerte und Kriteriumswerte) und berechne ein geeignetes Performancemaß für die Vorhersagen der neuen Daten
→ In der Praxis meist nicht durchführbar
 - **Naives Vorgehen:** Schätze den erwarteten Vorhersagefehler durch Berechnung des Performancemaßes in *derselben* Stichprobe, die bereits zur Schätzung des Modells verwendet wurde
→ Unterschätzung des erwarteten Vorhersagefehlers
 - **Empfohlenes Vorgehen:** Schlaues „Recyclen“ der vorliegenden Stichprobe für eine realistische Abschätzung des Vorhersagefehlers
→ Resampling Methoden

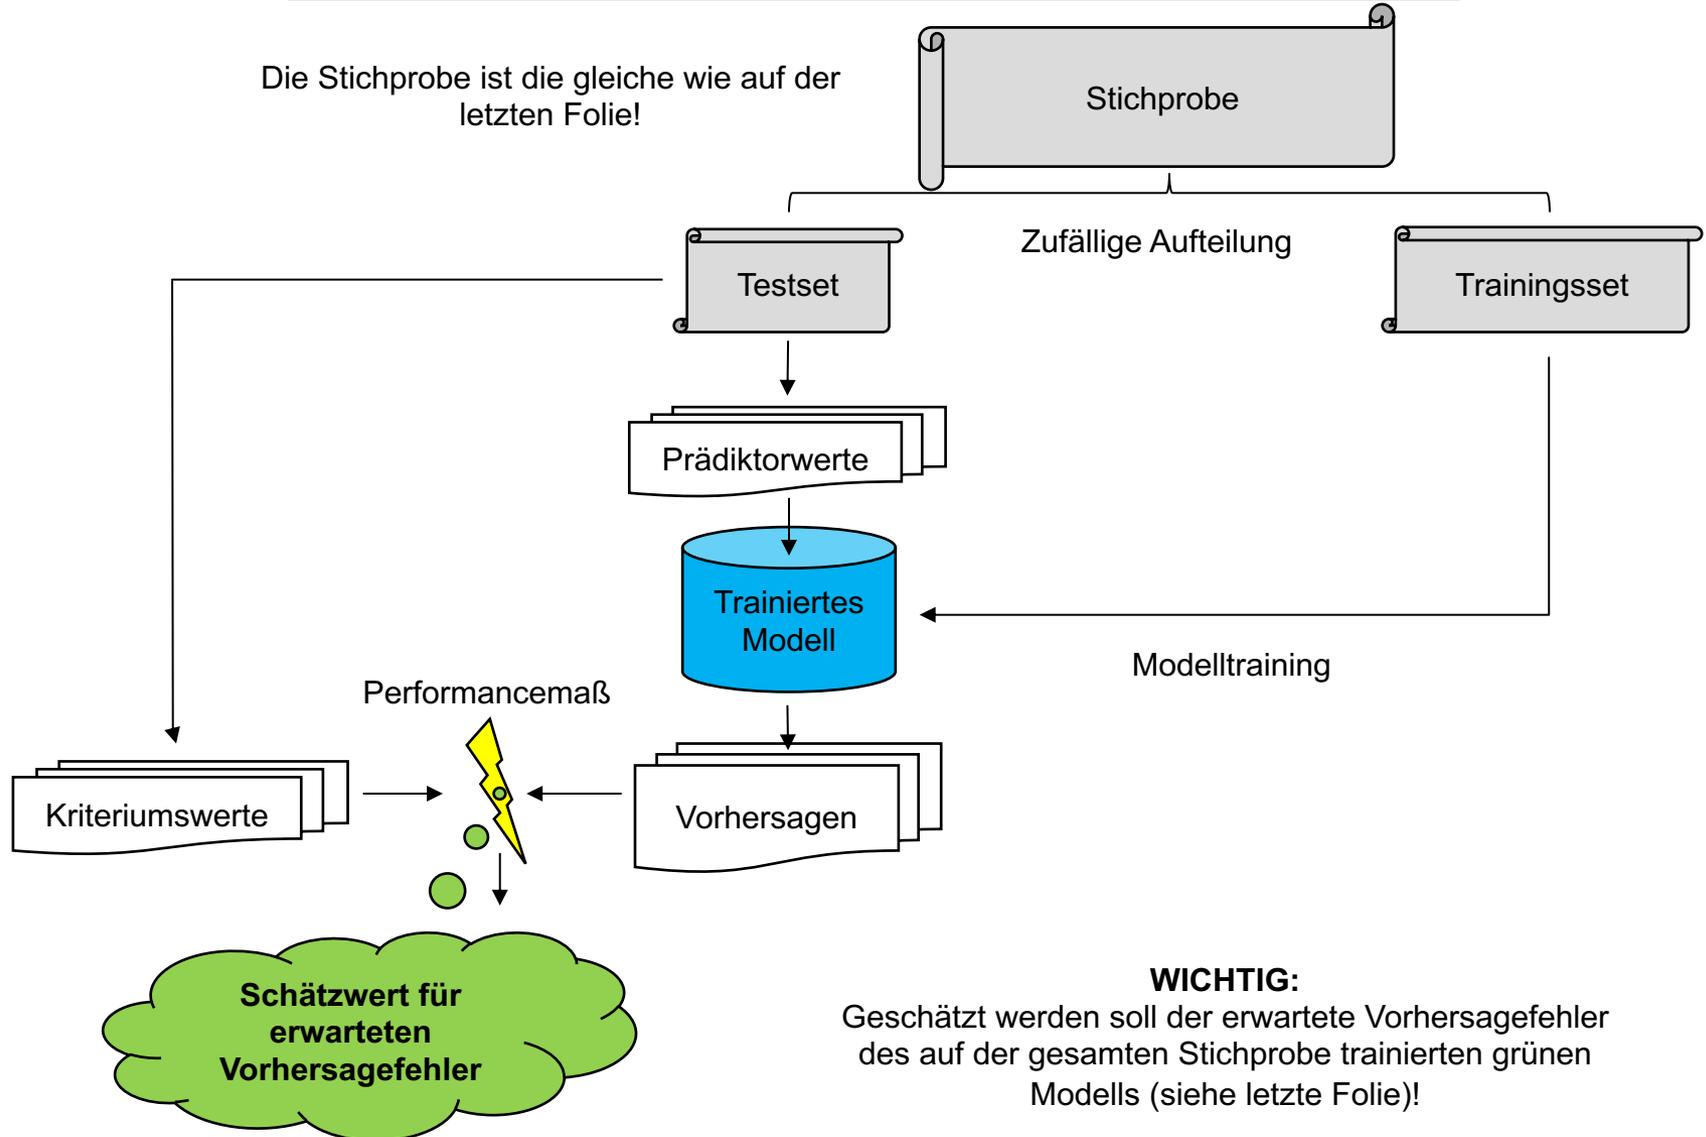
- Zur Modellevaluation teilt man den Gesamtdatensatz zufällig in zwei Teile
 - Trainingsset: Wird zum Trainieren des Modells verwendet
 - Testset: Wird zur Abschätzung der Vorhersagegüte verwendet
- Realistische Abschätzung des erwarteten Vorhersagefehlers des gesamten Modells durch die Berechnung der Vorhersagegüte im Testset
 - Schätze Modellparameter anhand der Beobachtungen im Trainingsset
 - Verwende das trainierte Modell zur Berechnung von Vorhersagen für die Beobachtungen im Testset
 - Vergleiche die Vorhersagen im Testset mit den tatsächlichen Kriteriumswerten anhand eines geeigneten Performancemaßes
- **Hinweis:** Im Folgenden wird von einer Regressionsfragestellung mit dem MSE als Performancemaß ausgegangen. Klassifikation oder Verwendung anderer Performancemaße funktioniert analog



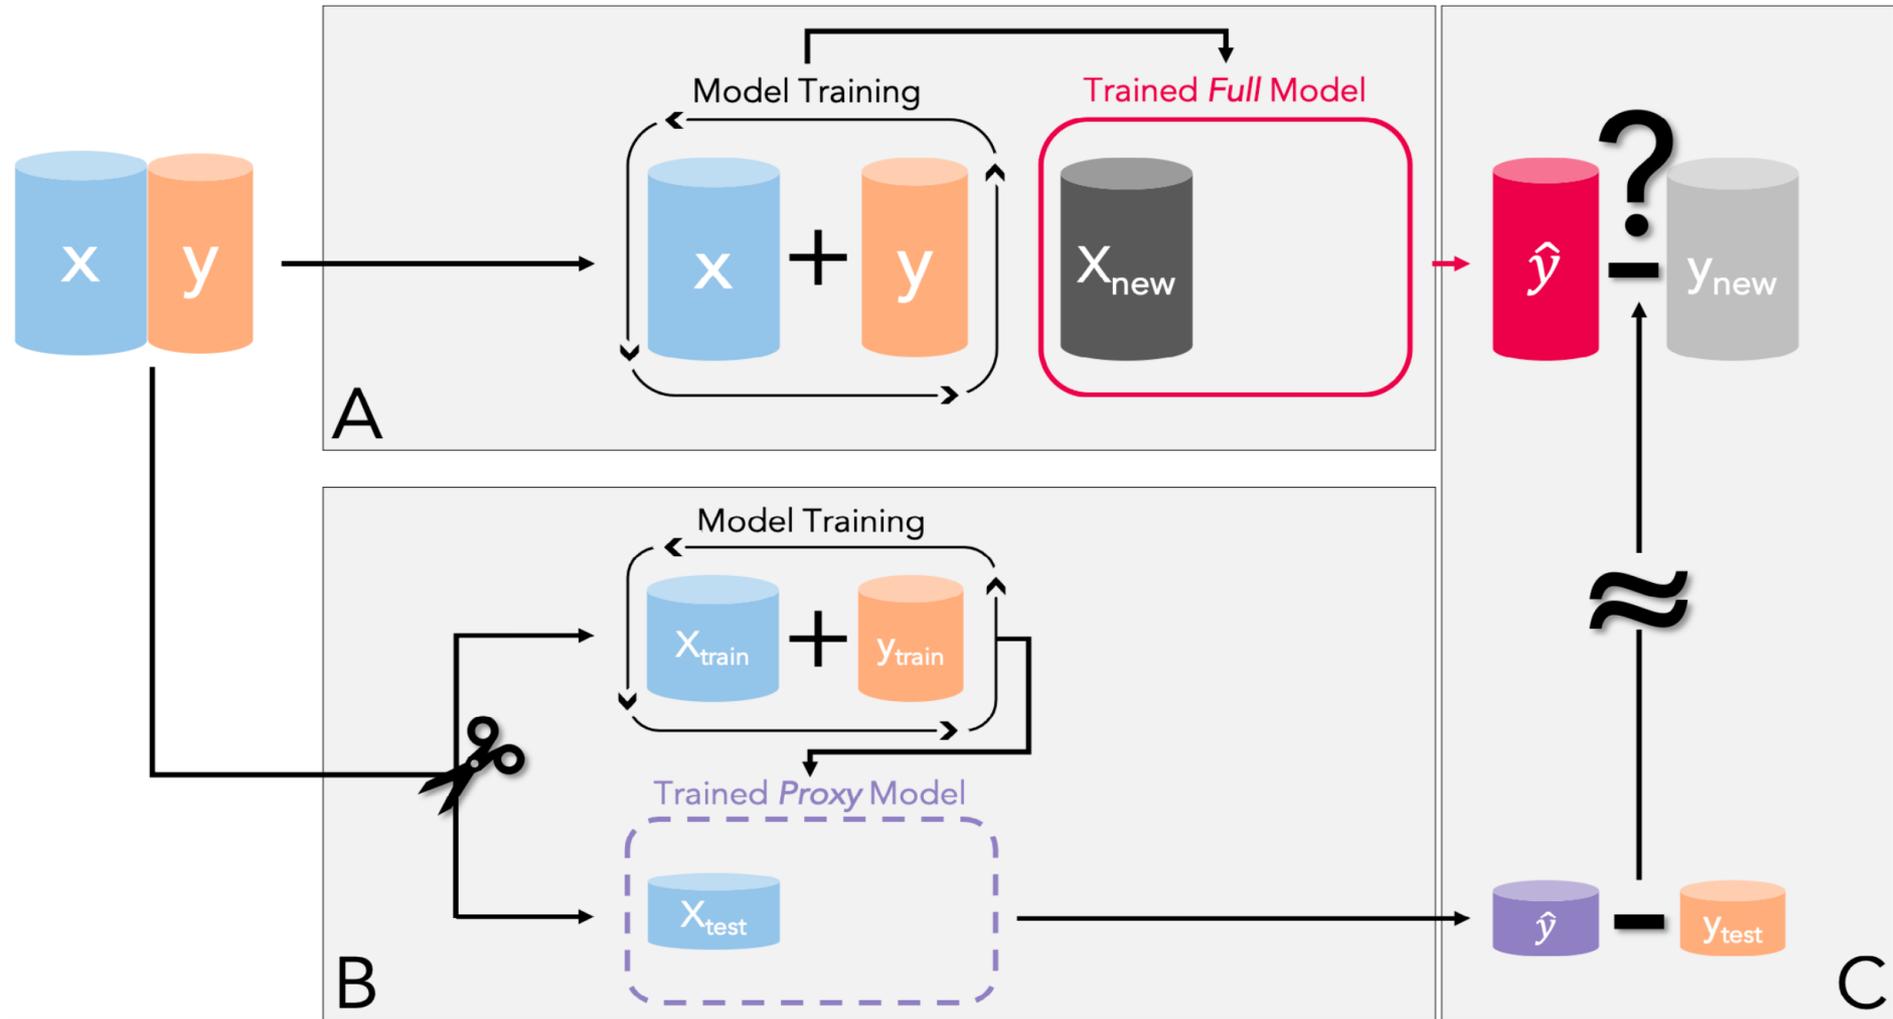
* Für zukünftige Daten aus der praktischen Anwendung liegen nur die Prädiktorwerte vor!

Veranschaulichung Trainings- und Testset

Die Stichprobe ist die gleiche wie auf der
letzten Folie!



Exkurs: Nochmal anders veranschaulicht (Pargent, Schödel, & Stachl, 2022)

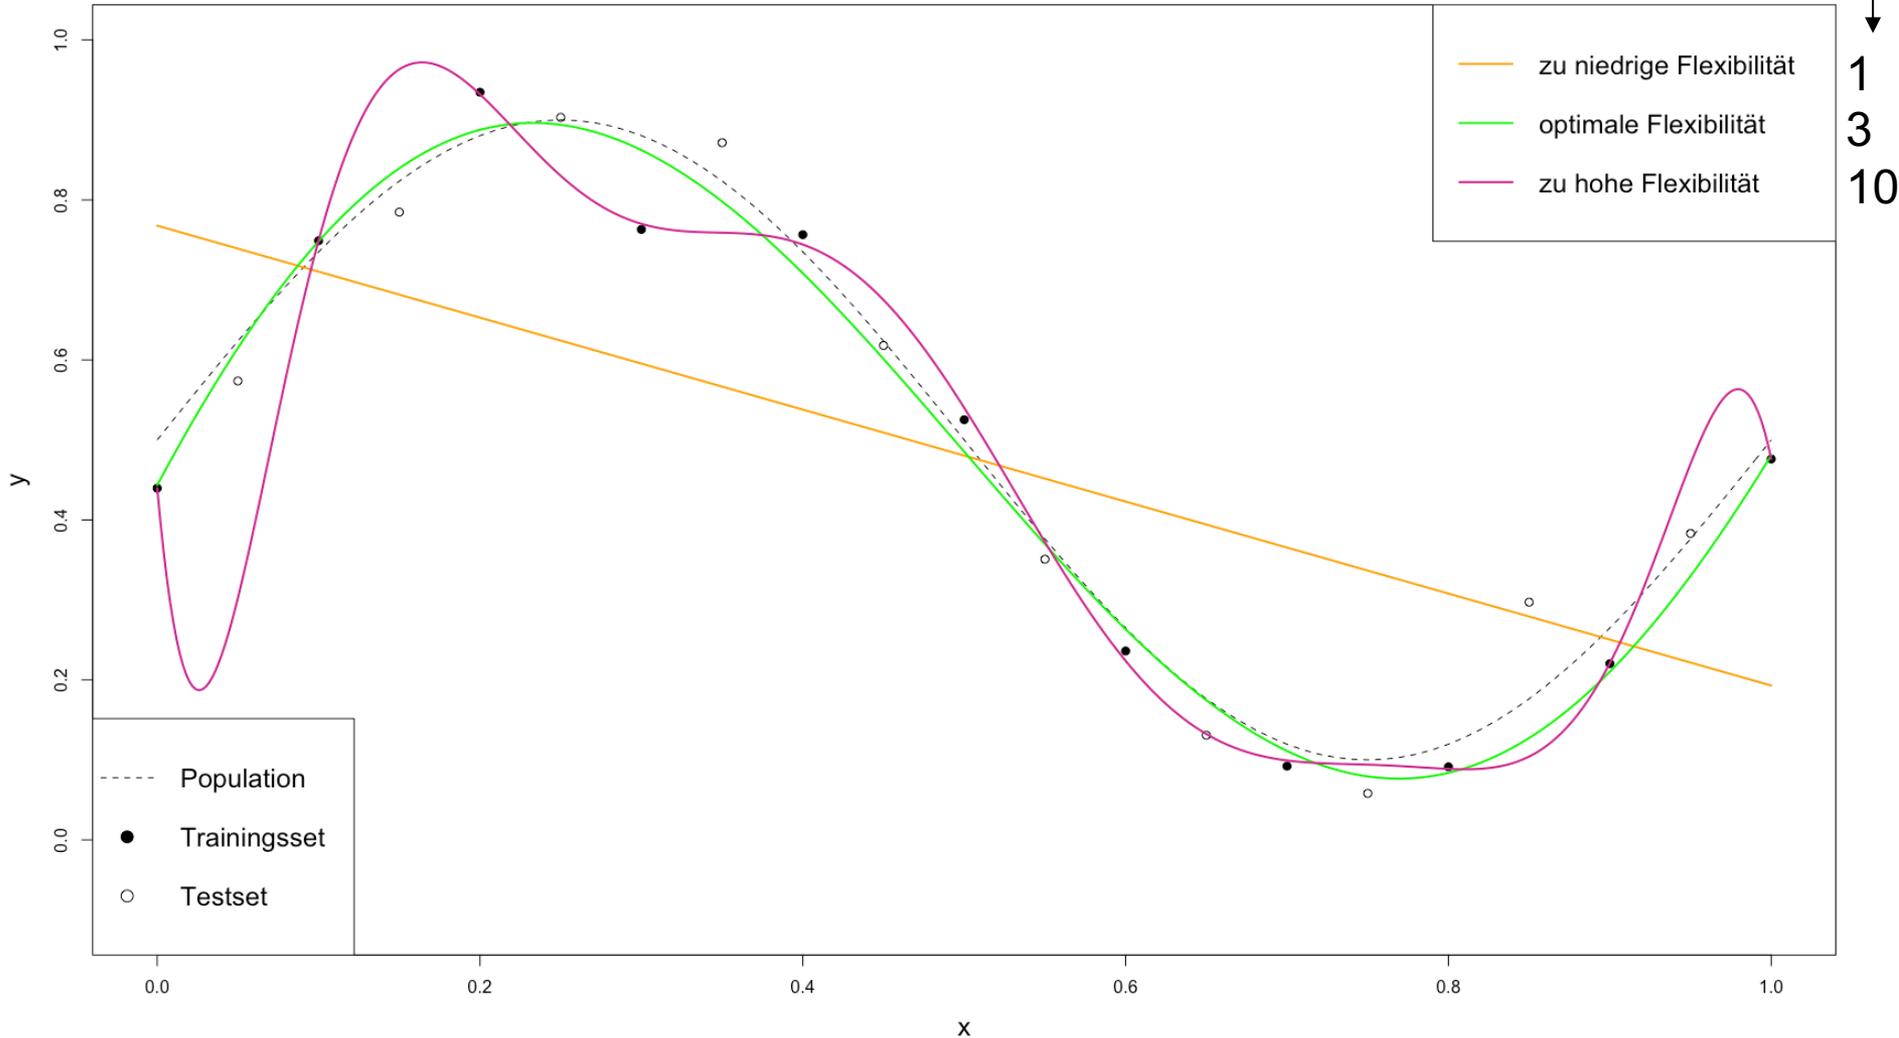


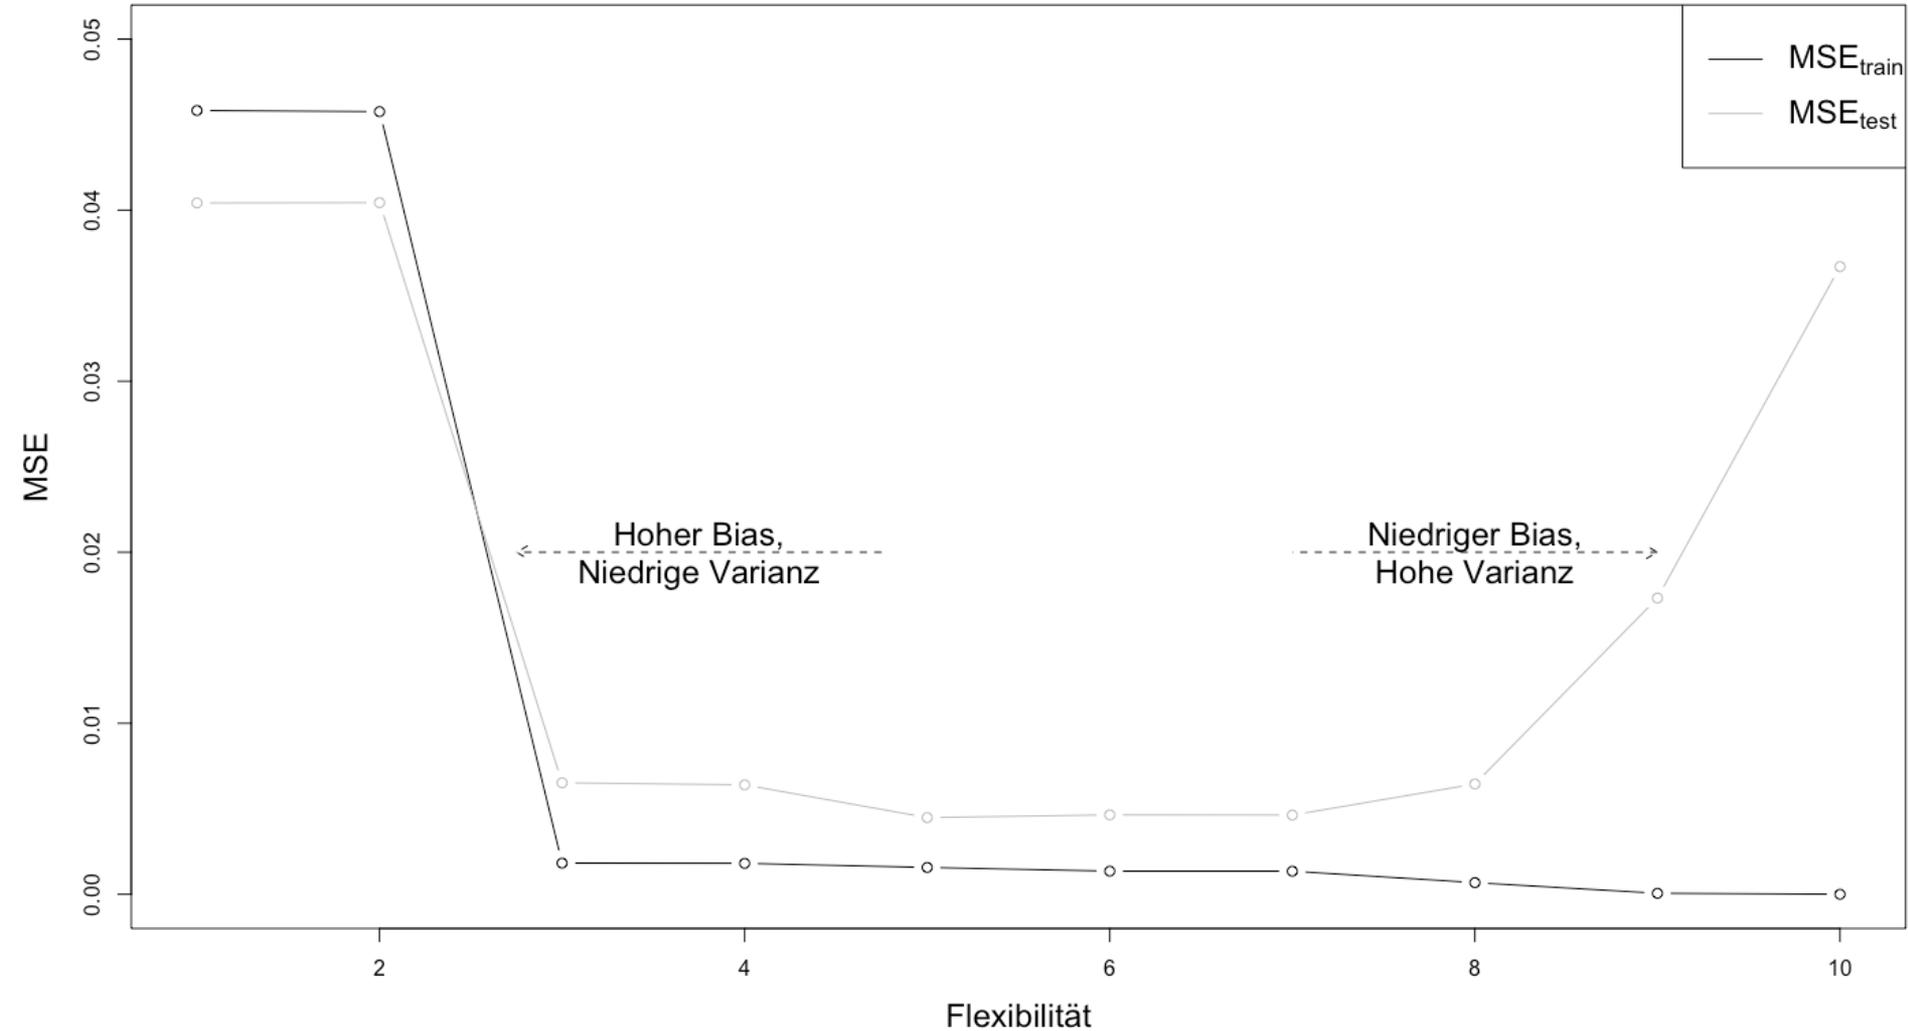
$$MSE_{train} = \frac{1}{N_{train}} \sum_{i=1}^{N_{train}} \left(y_{i,train} - \hat{y}_{i,train}^{(train)} \right)^2$$
$$MSE_{test} = \frac{1}{N_{test}} \sum_{i=1}^{N_{test}} \left(y_{i,test} - \hat{y}_{i,test}^{(train)} \right)^2$$

- $y_{i,train}$: Kriteriumswert von Person i aus dem Trainingsset
- $y_{i,test}$: Kriteriumswert von Person i aus dem Testset
- $\hat{y}_{i,train}^{(train)}$: Vorhergesagter Wert für Person i aus dem Trainingsset, mithilfe des prädiktiven Modells, welches am Trainingsset geschätzt wurde
- $\hat{y}_{i,test}^{(train)}$: Vorhergesagter Wert für Person i aus dem Testset, mithilfe des prädiktiven Modells, welches am Trainingsset geschätzt wurde
- $N = N_{train} + N_{test}$

- Im oben skizzierten Vorgehen mit genau einem Trainingsset und einem Testset wird MSE_{test} auch als „Holdout-Schätzer“ bezeichnet
- Die Bezeichnung Holdout-Schätzer ist unabhängig vom verwendeten Performancemaß, gilt also auch für z.B. R^2_{test} , $MMCE_{test}$, $SPEC_{test}$, ...
- Der Holdout-Schätzer ist die einfachste Resampling Prozedur, die eine vernünftige Abschätzung des erwarteten Vorhersagefehlers erlaubt

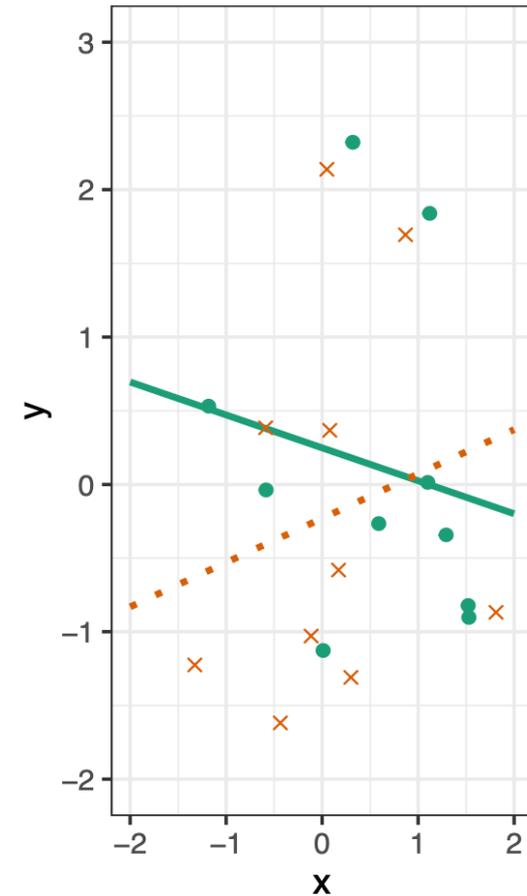
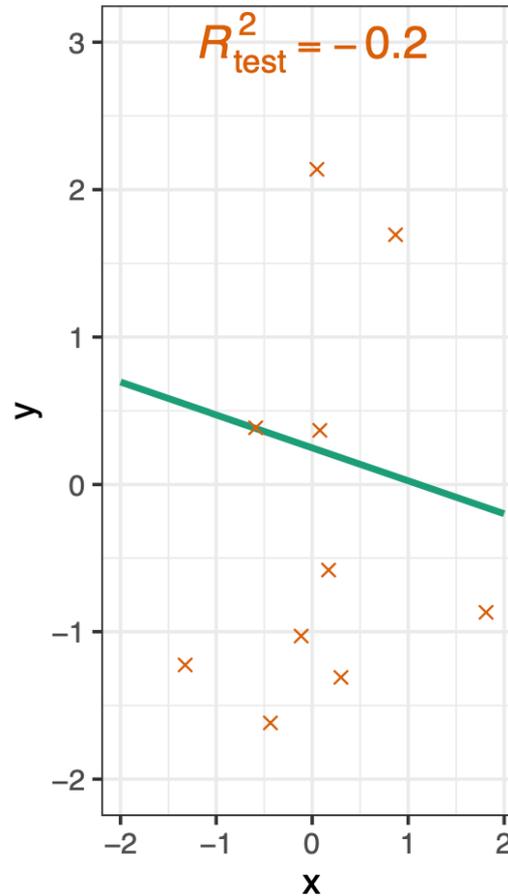
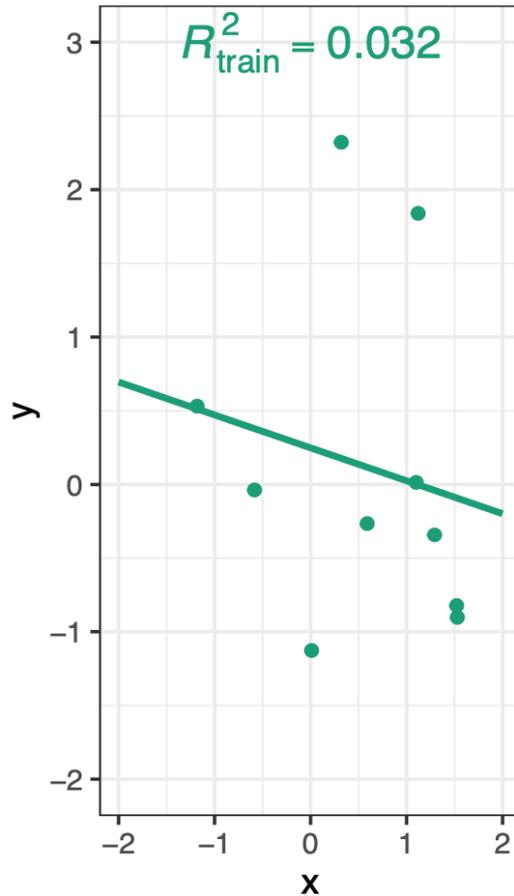
„Flexibilität“ = Grad des Polynoms





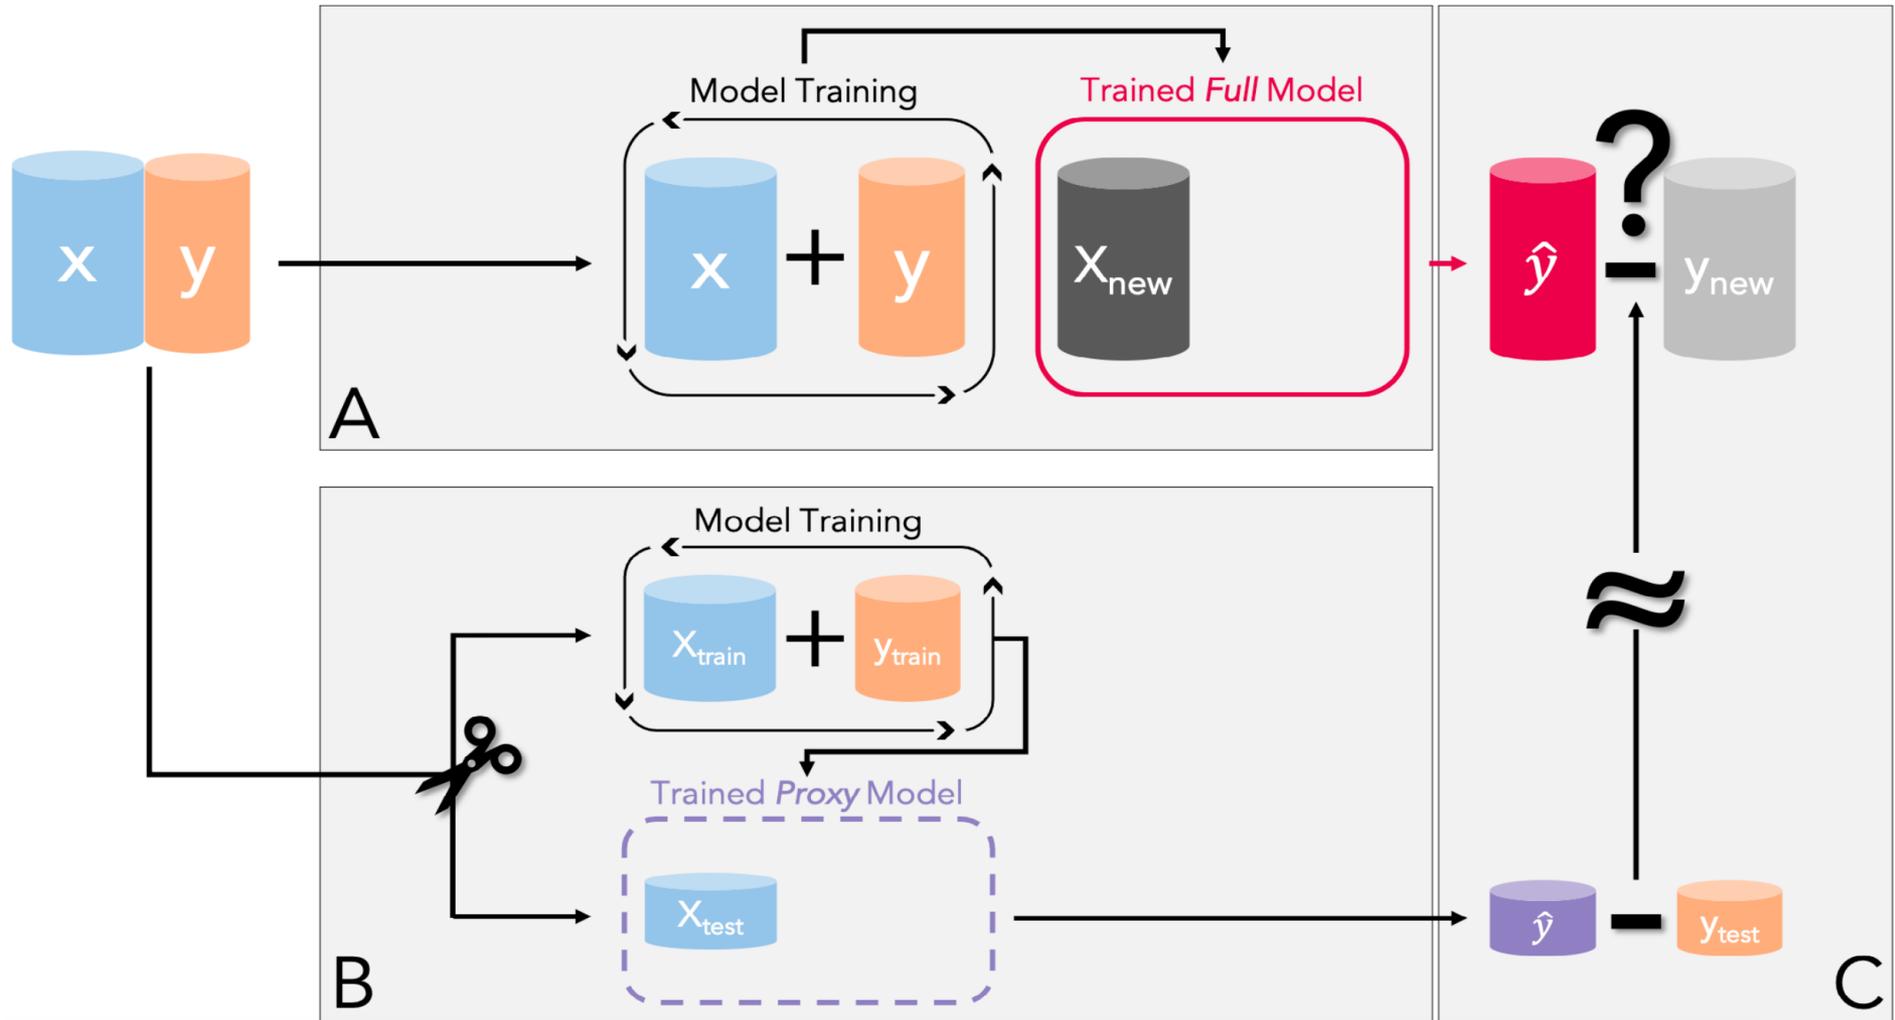
- Der Wertebereich von R^2 liegt allgemein im Intervall $]-\infty, 1]$
- Nur für R^2_{train} in der multiplen linearen Regression gilt: $R^2_{train} \in [0,1]$
 - durch die Methode der kleinsten Quadrate ist die schlechtmöglichste Vorhersage der multiplen linearen Regression innerhalb des Trainingssets die konstante Vorhersage des Mittelwerts \bar{y} (dann gilt: $R^2_{train} = 0$)
- Interpretation von $R^2_{test} < 0$:
 - Das prädiktive Modell trifft schlechtere Vorhersagen als ein Modell, welches für jede Beobachtung immer den Mittelwert im Kriterium \bar{y} vorhersagt, d.h. die Werte auf den Prädiktoren komplett ignoriert
 - Ein nützliches Modell muss immer das triviale Modell mit konstanter Vorhersage schlagen, d.h. ein positives R^2 haben
 - Ein negatives R^2_{test} zeigt häufig Overfitting an
- **Fazit:** Bei der Anwendung prädiktiver Modelle in der Praxis ist es möglich, schlechtere Vorhersagen zu erzielen als durch „schlaues Raten“

Negatives R^2

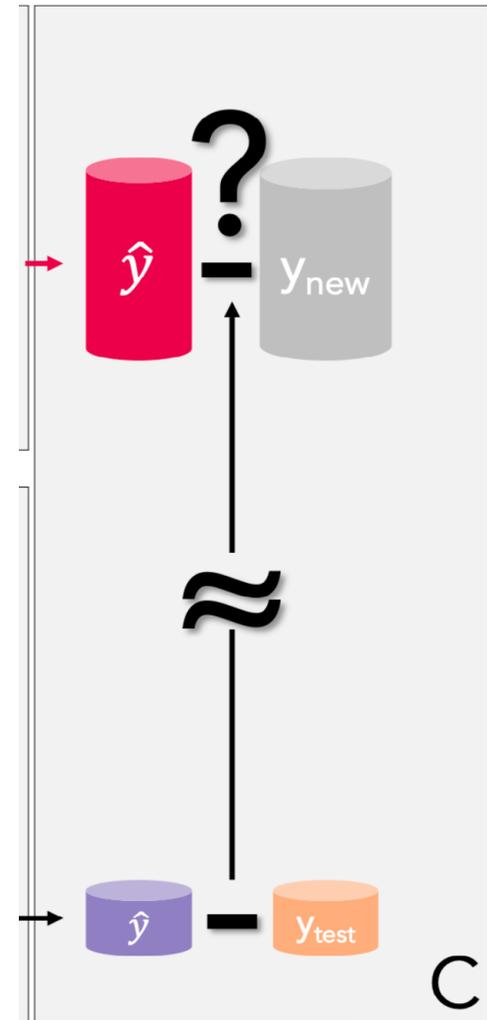


- Trainiere Modell anhand der Trainingsdaten (grün)
- Positives R^2_{train} für die Trainingsdaten
- Vorhersage der (orange) Testdaten mithilfe des trainierten Modells (grün)
- Negatives R^2_{test}
- Zusammenhang im Testset ist positiv, Zusammenhang im Trainingsset ist negativ

Wdh: Performance im Testset als Schätzer für Gesamtperformance



- Der Holdout-Schätzer stellt eine Schätzfunktion für den erwarteten Vorhersagefehler des auf der **gesamten** Stichprobe trainierten Modells dar.
- Ist das ein guter Schätzwert? Die Güte dieser Schätzfunktion hängt ab von deren ...
 - Bias: Entspricht der Mittelwert des Holdout-Schätzers bei wiederholten Stichproben dem erwarteten Vorhersagefehler?
 - Varianz: Wie stark unterscheiden sich die Schätzwerte des Holdout-Schätzers zwischen wiederholten Stichproben?
- Bias und Varianz hängen stark vom gewählten Größenverhältnis von Trainings- und Testset ab.




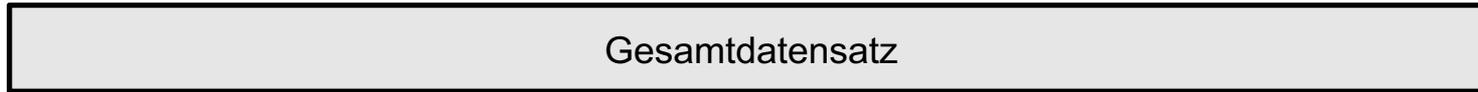
- Generell gilt: Je mehr Daten zur Schätzung eines prädiktiven Modells verwendet werden, desto präziser sind dessen Vorhersagen
- Da das Trainingsset immer kleiner ist als der Gesamtdatensatz, wird die Genauigkeit des gesamten prädiktiven Modells tendenziell unterschätzt
 - Bias ist größer, je kleiner das Trainingsset
- Generell gilt: Je mehr Daten zur Berechnung der Performance verwendet werden, desto präziser wird der erwartete Vorhersagefehler geschätzt (siehe Standardfehler des Mittelwerts bei unabhängigen Beobachtungen)
 - Varianz ist größer, je kleiner das Testset
- Es gilt immer: Je größer das Trainingsset, desto kleiner das Testset
 - Es ist nicht möglich sowohl Bias als auch Varianz zu minimieren
 - Optimaler Tradeoff von Bias und Varianz nicht eindeutig zu bestimmen

- Wie groß soll das Trainingsset im Verhältnis zum Testset optimalerweise gewählt werden?
- Daumenregel zur Aufteilung in Trainings- und Testset:
 - Trainingsset: $\frac{2}{3}$ des Gesamtdatensatzes
 - Testset: $\frac{1}{3}$ des Gesamtdatensatzes

- Kann der Holdout-Schätzer durch eine schlauere Aufteilung in Trainings- und Testdaten noch verbessert werden?
- Beispiel:
 - Teile den Gesamtdatensatz auf in ein Trainings- und Testset mit gleicher Größe
 - Vergleiche den Holdout-Schätzer mit folgendem Vorgehen:
 - Berechne Holdout-Schätzer
 - Vertausche Trainings- und Testset
 - Berechne Holdout-Schätzer erneut
 - Berechne Mittelwert der beiden Holdout-Schätzer
→ 2-Fold Cross-Validation (2-Fold CV)
- Bei gleicher Größe des Trainingssets hat der 2-Fold CV Schätzer den gleichen Bias wie der Holdout-Schätzer, aber eine niedrigere Varianz
→ Grund: Mitteln über zwei Testsets der gleichen Größe wie bei Holdout

- Zufällige Aufteilung des Datensatzes in K gleich große Teile („Folds“)
- Verwende jeden der K Teile einmal als Testset und die anderen $K-1$ Teile als das dazu gehörige Trainingsset
- Berechne MSE_{test} (oder anderes Maß) für jedes der K Testsets. Für die Vorhersagen verwende das Modell aus dem jeweiligen Trainingsset
- Schätze den erwarteten Vorhersagefehler durch den Mittelwert von MSE_{test} über alle K Testsets
- Ähnlich wie beim Holdout-Schätzer ist die optimale Anzahl an Folds nicht eindeutig zu bestimmen
 - In der Praxis werden meist 5 oder 10 Folds verwendet
 - Es gilt **nicht**: Je mehr Folds desto besser (weil bei vielen Folds ja wiederum das Testset immer kleiner wird)
- Weitere Resampling Methoden:
Repeated Cross-Validation, Bootstrap, Subsampling

Beispiel 3-Fold Cross-Validation



Zufällige
Aufteilung



$MSE_{test}^{(1)}$



$MSE_{test}^{(2)}$



$MSE_{test}^{(3)}$

$$MSE_{cv} = \frac{1}{3} \left(MSE_{test}^{(1)} + MSE_{test}^{(2)} + MSE_{test}^{(3)} \right)$$

$$MSE_{test}^{(k)} = \frac{1}{N_k} \sum_{i=1}^{N_k} \left(y_{i,k} - \hat{y}_{i,k}^{(train_k)} \right)^2$$

MSE aus
dem Fold k

$$MSE_{CV} = \frac{1}{K} \sum_{k=1}^K MSE_{test}^{(k)}$$

MSE über alle K
folds gemittelt

- K : Anzahl der Folds
- N_k : Anzahl von Beobachtungen in Fold k
- $y_{i,k}$: Kriteriumswert der i – ten Person in Fold k
- $\hat{y}_{i,k}^{(train_k)}$: Vorhergesagter Wert für die i – te Person aus Fold k mithilfe des prädiktiven Modells, welches anhand des zu Fold k gehörenden Trainingssets (besteht aus allen Folds außer Fold k) geschätzt wurde
- $N = N_1 + \dots + N_K$

- Der beste Weg die Vorhersagegüte prädiktiver Modelle in einem konkreten Anwendungsfall zu verbessern, besteht in der Erhöhung der zur Verfügung stehenden Stichprobe.
- **Gründe:** Je größer die Stichprobe, desto...
 - geringer die Varianz der Vorhersagen
 - größer das Potential flexiblerer Modellklassen mit niedrigem Bias
 - geringer die Gefahr von Overfitting
 - mehr Prädiktoren können sinnvoll genutzt werden
- Außerdem gilt: Je größer die Stichprobe, desto genauer kann für ein trainiertes prädiktives Modell der erwartete Vorhersagefehler abgeschätzt werden (weil man dann auch das Testset entsprechend größer machen kann).

- Kennenlernen eines prädiktiven Standardmodells bei Regressions- und Klassifikationsfragestellungen, das mit sehr vielen Prädiktorvariablen umgehen kann und trotzdem noch ähnlich gut interpretierbar ist wie multiple lineare und logistische Regressionsmodelle.
- Regularisierte lineare und logistische Regression (LASSO)