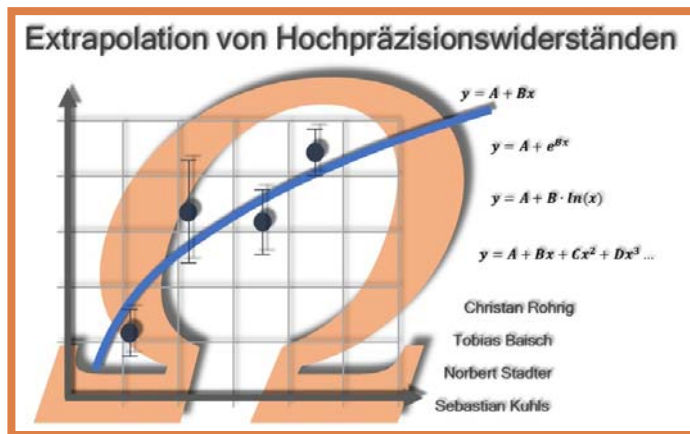


# Extrapolation von Hochpräzisionswiderständen

Tobias Baisch, Sebastian Kuhls, Christian Rohrig, Norbert Stadter



# Agenda

## 1 Einleitung

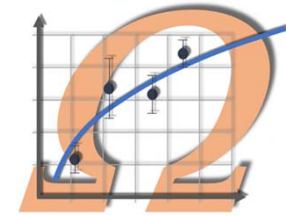
## 2 Regressionsberechnung

- **Unsicherheitsberechnung**
- **Gewichtung**
- **Probleme**

## 3 Behandlung von Ausreißern

# Einleitung

## Hochpräzisionswiderstände



3

□ Widerstände reagieren empfindlich auf Änderungen von

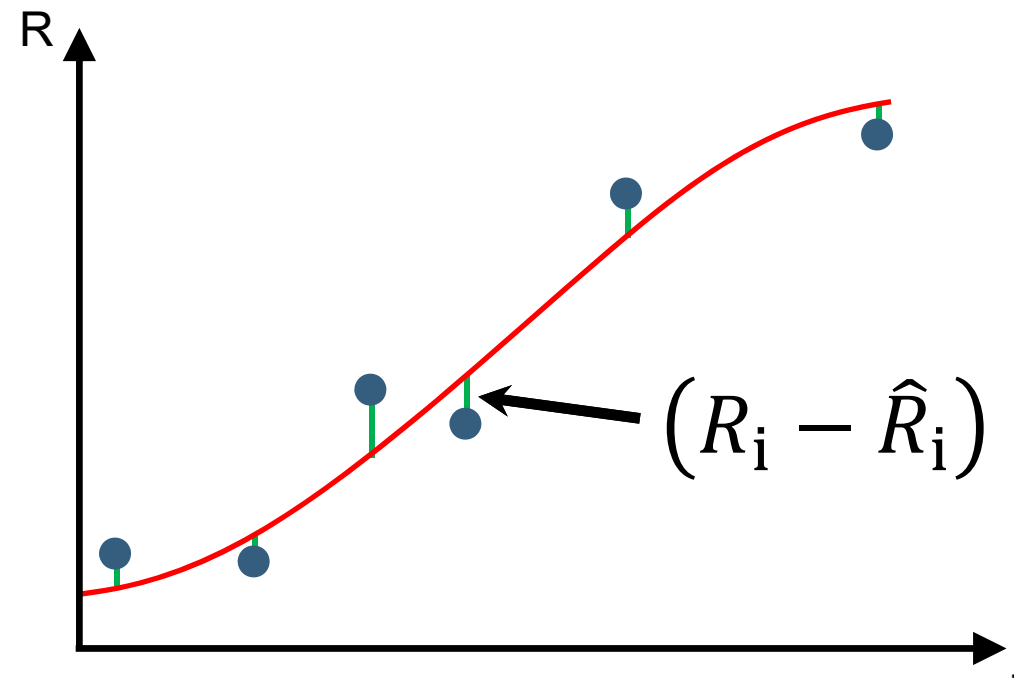
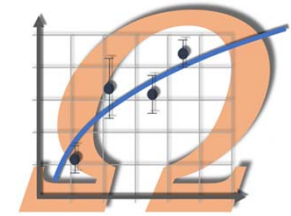
□ Temperatur

□ Feuchte

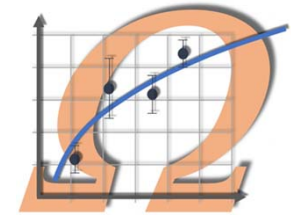
□ Druck

□ Zeit





- Methode der kleinsten Fehlerquadrate
- Nach Carl Friedrich Gauß



□ Linear

$$\hat{R} = A + B \cdot t$$

□ Polynom

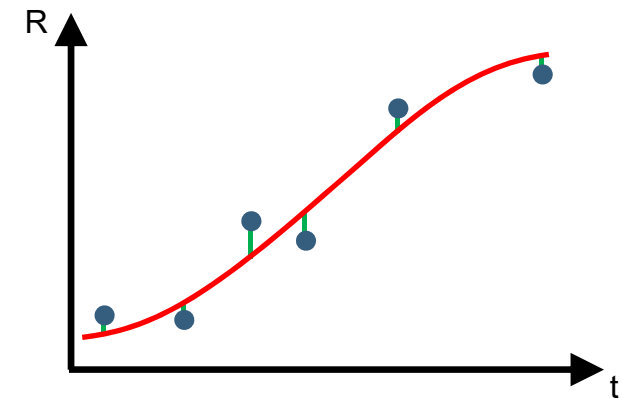
$$\hat{R} = A + B \cdot t + C \cdot t^2$$

□ Logarithmisch

$$\hat{R} = A + B \cdot \ln(t)$$

□ Exponentiell

$$\hat{R} = \alpha + \exp(\beta \cdot t)$$

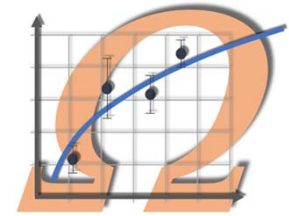


Werden in der Praxis  
nicht verwendet.

Warum?

# Regressionsberechnung

## Beispiel



6

- Linearer Ansatz

$$\hat{R} = (A + B \cdot t)$$

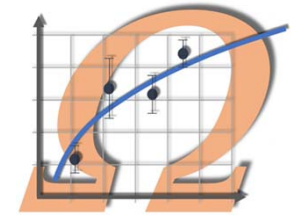
- Summe der Quadrate der Abweichungen

$$\sum_{i=1}^k (R_i - \hat{R})^2$$

$$\sum_{i=1}^k (R_i - \boxed{A + B \cdot t})^2$$

# Regressionsberechnung

## Beispiel



7

$$V = \sum_{i=1}^k (R_i - (A + B \cdot t))^2$$

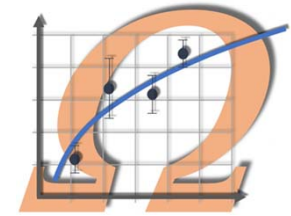
partielle Ableitung  $\partial V / \partial A$  und  $\partial V / \partial B$

Minimum der Fehlerquadrate:  
Durch Ableitungen und setzen von  $V = 0$

„Lineares“ Gleichungssystem nach A und B lösen  
Ergebnis: Regressionsfunktion  $\hat{R} = A + B \cdot t$

# Regressionsberechnung

## Beispiel



8

- Vereinfachung nach M. Blaha

$$B = \frac{\sigma(t,R)}{\sigma(t)}$$

**Kovarianz**  $= \frac{1}{n-1} \sum [(t - \bar{t})(R - \bar{R})]$

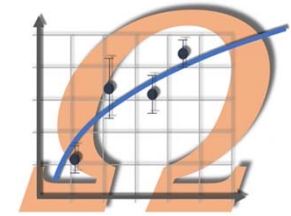
**Varianz**  $= \frac{1}{n-1} \sum (t - \bar{t})^2$

$$A = \bar{R} - B \cdot \bar{t}$$

$$\hat{R} = A + B \cdot t$$

# Regressionsberechnung

## Beispiel



9

- Vereinfachung nach M. Blaha

$$B = \frac{\sigma(t,R)}{\sigma(t)}$$

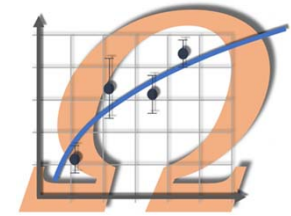
Kovarianz  $= \frac{1}{n-1} \sum [(t - \bar{t})(R - \bar{R})]$

$$A = \bar{R} - B \cdot \bar{t}$$

Varianz  $= \frac{1}{n-1} \sum (t - \bar{t})^2$

$$\hat{R} = A + B \cdot t$$

Mittelwerte



10

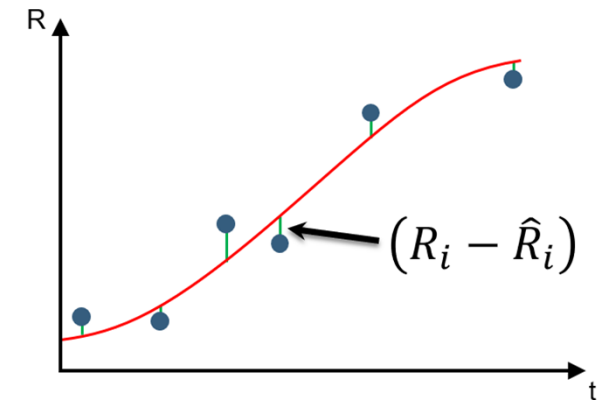
- Standardabweichung der Residuen

$$\sigma_R^2 = \frac{1}{n-2} \sum (R_i - A - B \cdot t_i)^2$$

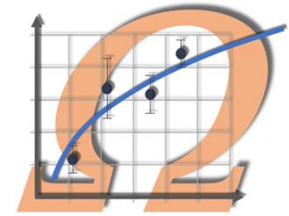
- Koeffizienten

$$\sigma_A^2 = \frac{\sigma_R^2 \sum t_i^2}{\Delta_{li}}$$

$$\sigma_B^2 = \frac{\sigma_R^2 \cdot N}{\Delta_{li}}$$

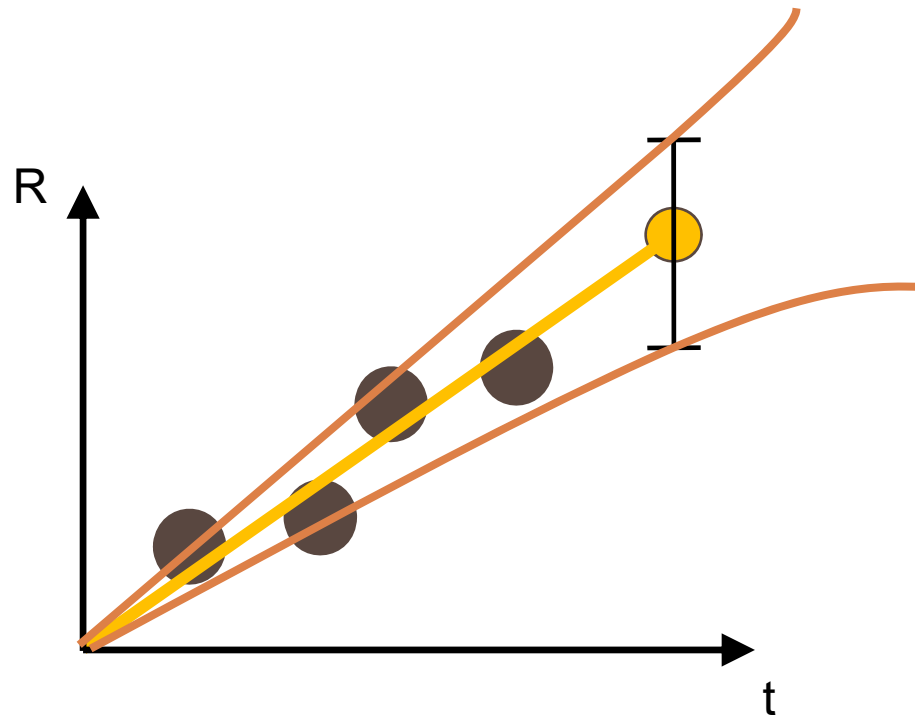


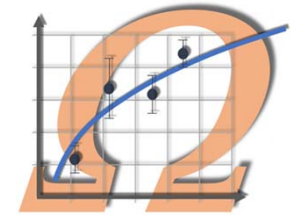
$\Delta_{li}$  - Determinante der Koeffizientenmatrix



- Standardunsicherheit

$$u(\hat{R}) = \sqrt{\sigma_R^2 + \sigma_A^2 + \sigma_B^2}$$



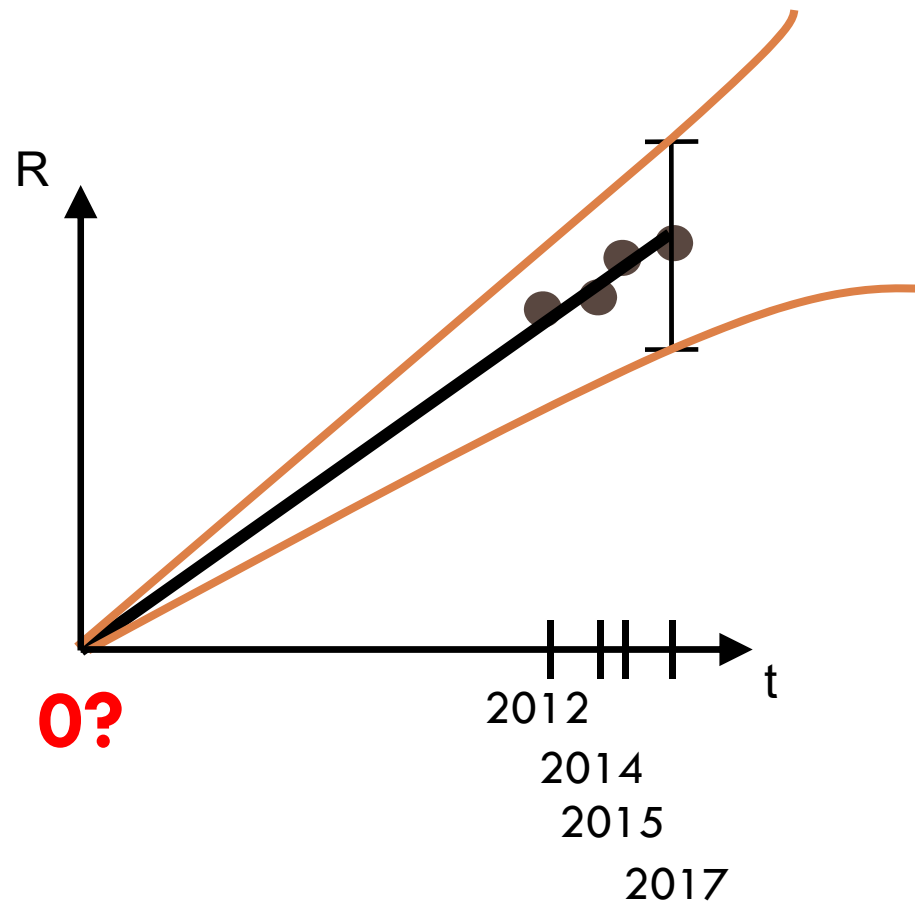


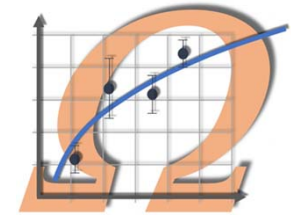
12

### □ Problem:

- Umwandlung von Datum in Zahlen
- Ursprung **beliebig**
- Größenordnung  $10^4$  bis  $10^{18}$

### □ Literatur nicht eindeutig

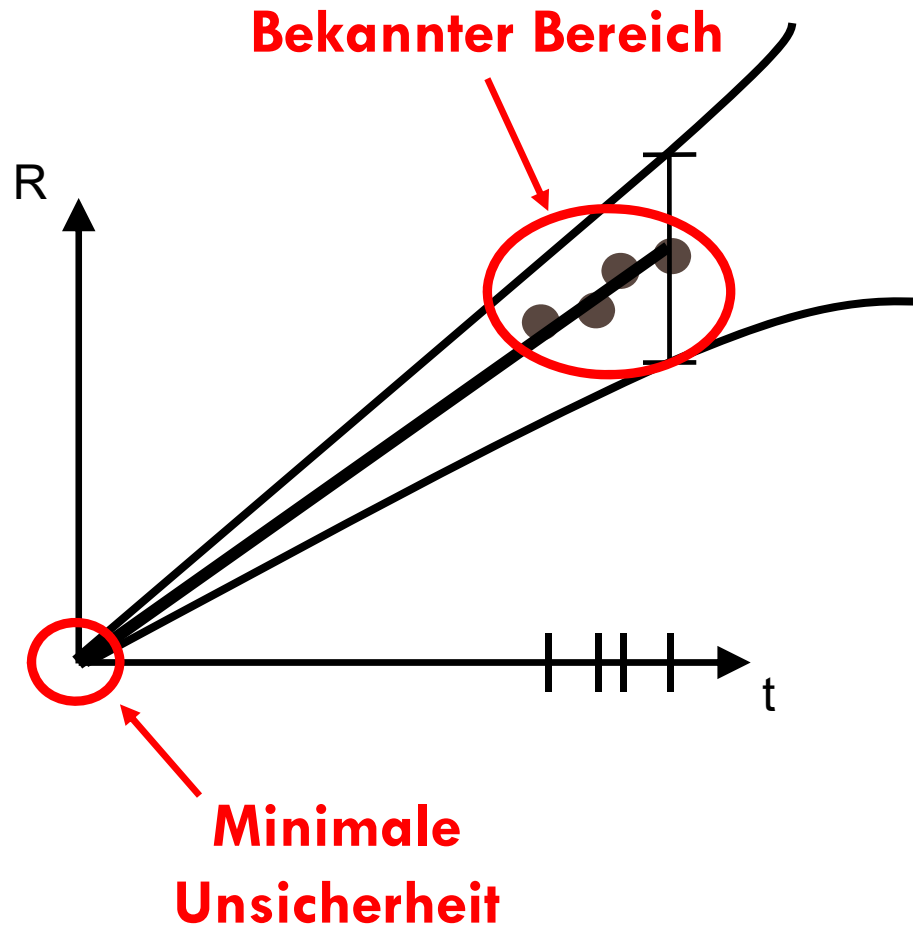


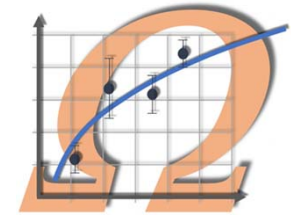


### □ Problem:

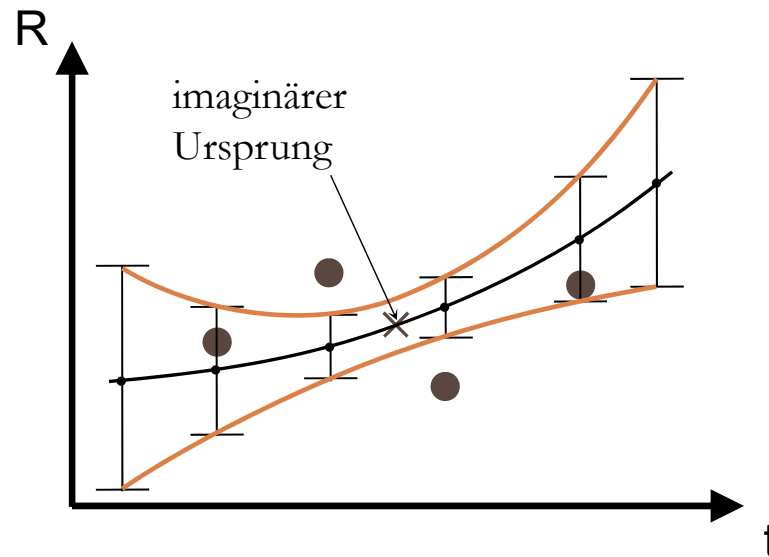
- Umwandlung von Datum in Zahlen
- Ursprung **beliebig**
- Größenordnung  $10^4$  bis  $10^{18}$

### □ Literatur nicht eindeutig

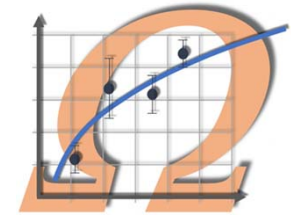




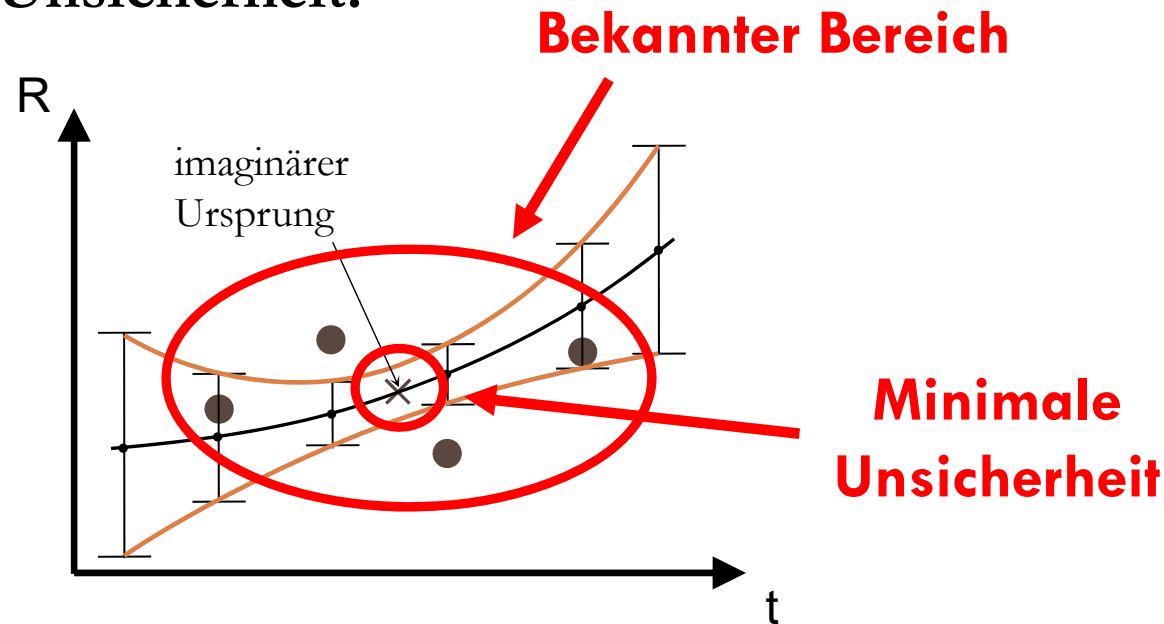
### □ Zeitbezug der Unsicherheit:



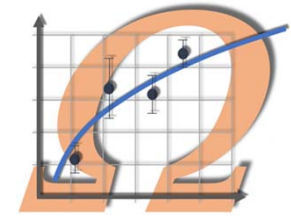
- Mittelwertbildung bei Berechnung
- Imaginärer Ursprung = Mittelwert aus Datumswerten



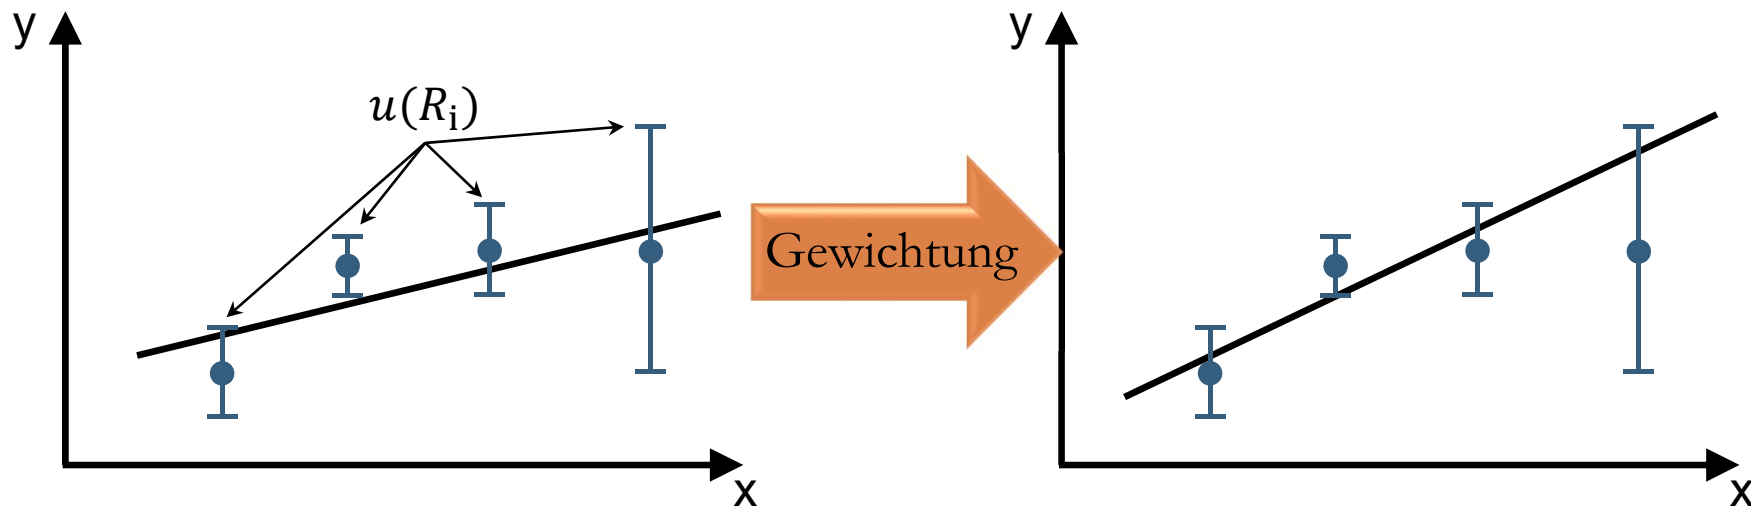
- Zeitbezug der Unsicherheit:



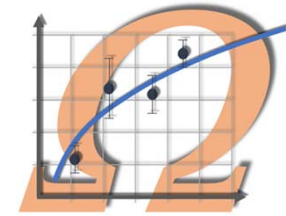
- Mittelwertbildung bei Berechnung
- Imaginärer Ursprung = Mittelwert aus Datumswerten



16



- Schwächere Wertung von Messwerten mit großer Unsicherheit
- Gewichtungsfaktor  $w_i = \frac{1}{u(R_i)^2}$



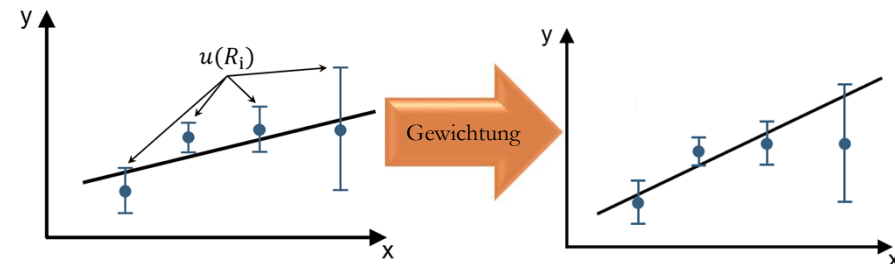
### □ Beispiel lineare Regression

$$A = \frac{(\sum w_i t_i^2) (\sum w_i R_i) - (\sum w_i t_i) (\sum w_i t_i R_i)}{(\sum w_i) (\sum w_i t_i^2) (\sum w_i t_i)^2}$$

$$B = \frac{(\sum w_i) (\sum w_i t_i R_i) - (\sum w_i t_i) (\sum w_i R_i)}{(\sum w_i) (\sum w_i t_i^2) (\sum w_i t_i)^2}$$

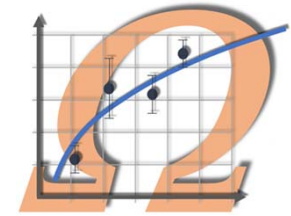
□ Schwächere Wertung von Messwerten mit großer Unsicherheit

□ Gewichtungsfaktor  $w_i = \frac{1}{u(R_i)^2}$



# Regressionsberechnung

## Probleme



18

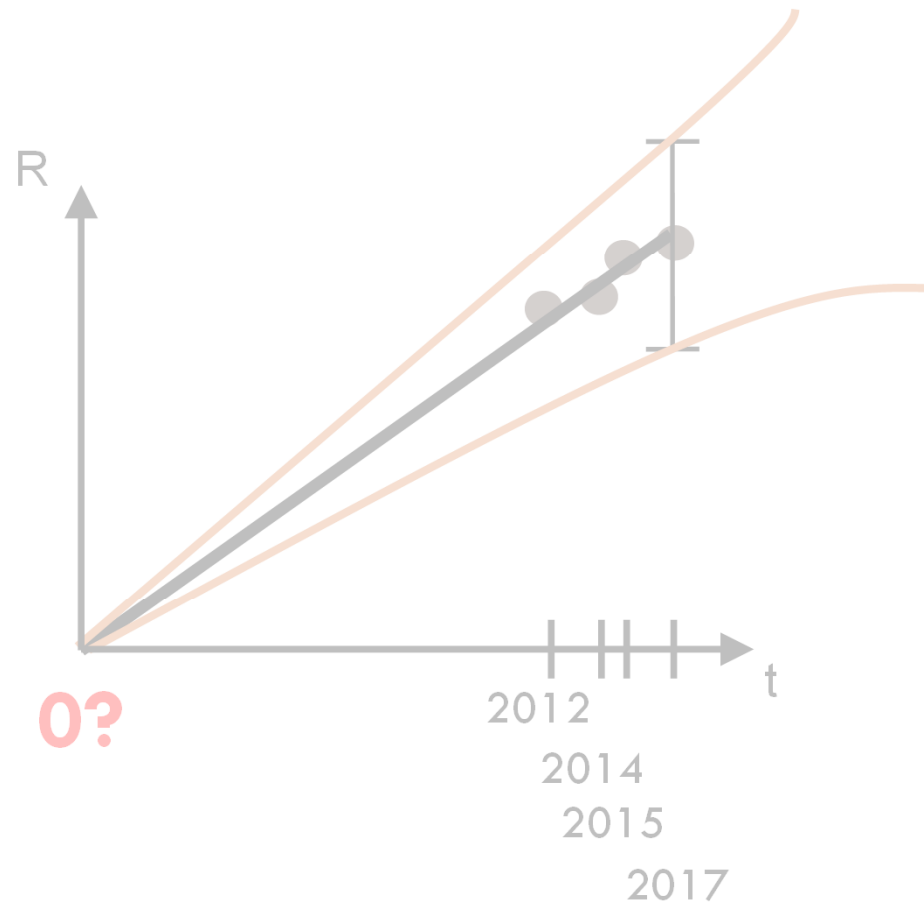
### □ Problem:

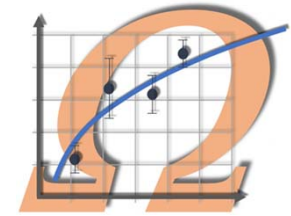
▣ Umwandlung von Datum  
in Zahlen

▣ Ursprung **beliebig**

▣ Größenordnung  
 $10^4$  bis  $10^{18}$

□ Literatur nicht eindeutig





19

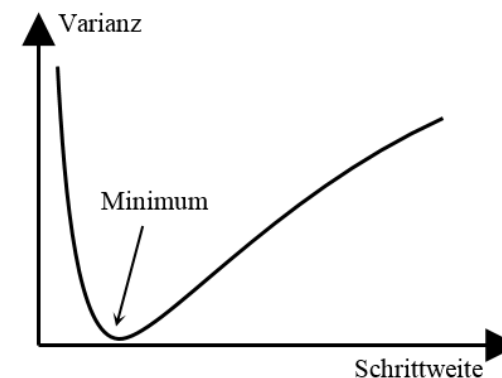
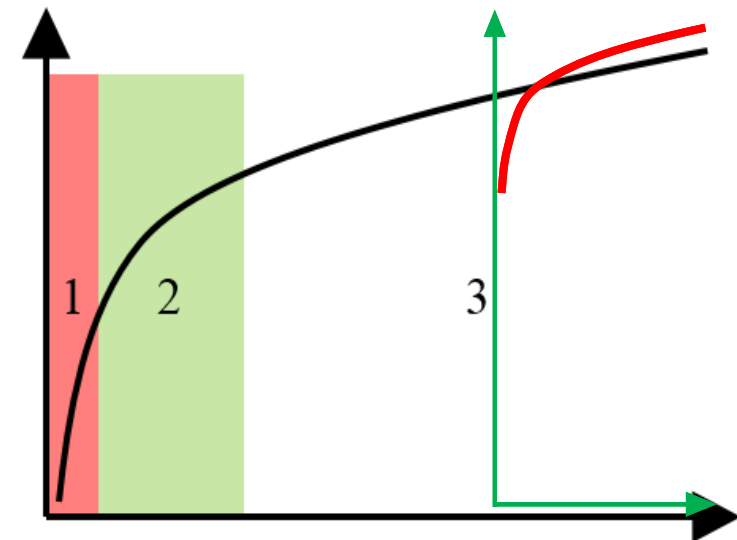
### □ Logarithmische Funktion

- ▣ 1 – Steigung: hoch      Krümmung: gering
- ▣ 2 – Steigung: mittel      Krümmung: stark
- ▣ 3 – Steigung: gering      Krümmung: gering

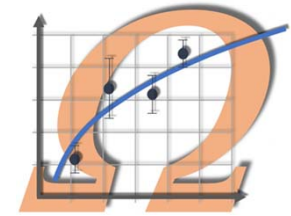
□  $\ln(1) = 0$

□ Kaum Unterschied zu linearer Regression

□ Verschiebung des Ursprungs

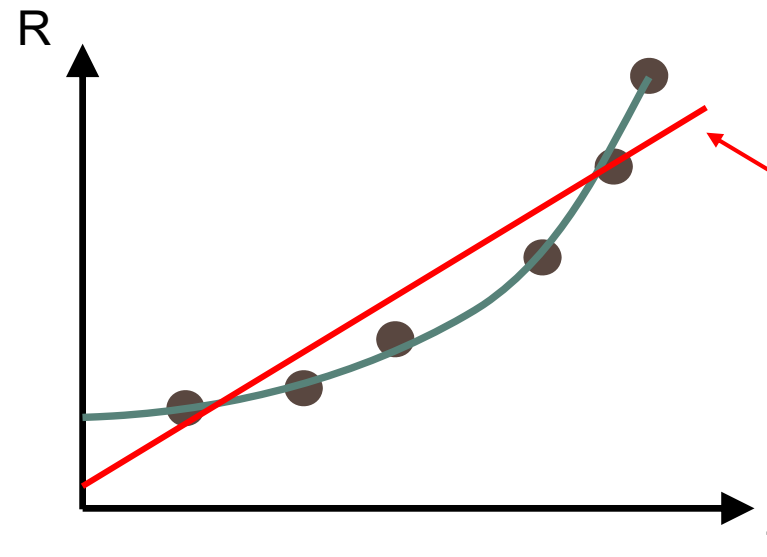


# Probleme bei exponentiellem Ansatz



20

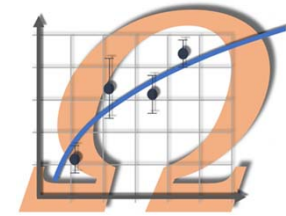
- Analog zur logarithmischen Berechnung
- Achsen vertauscht
  - ▣ Logarithmieren der Messwerte anstelle des Datums



Resultat aus gängigen  
Programmen

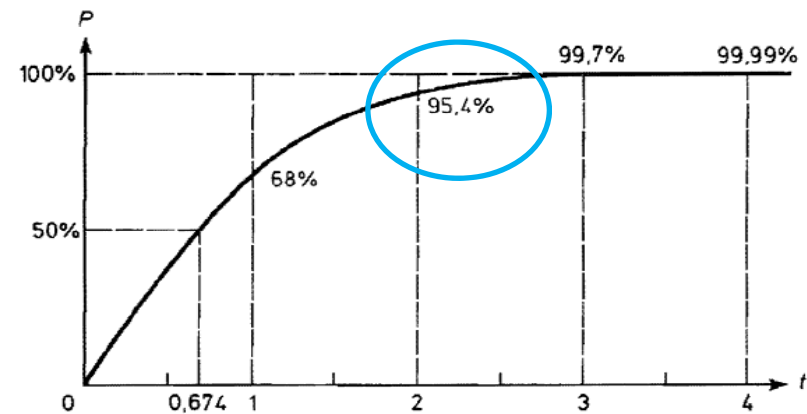
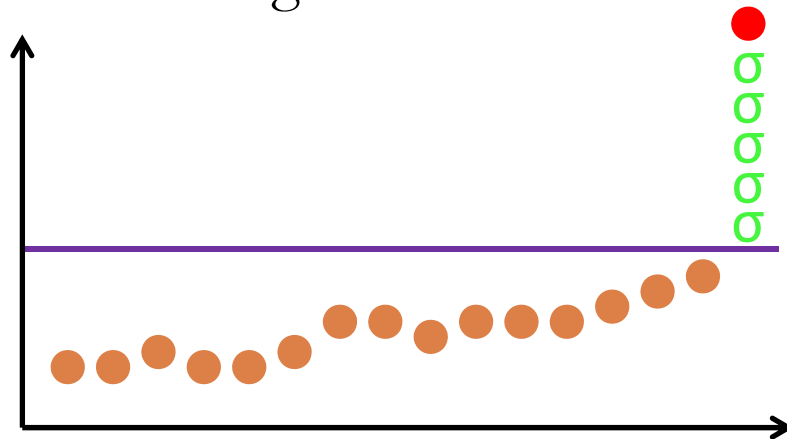
# Behandlung von Ausreißern

## Chauvenetsches Kriterium



21

- Darf man auffällige Werte vernachlässigen?
- Messungen können nicht wiederholt werden
- Berechnung:



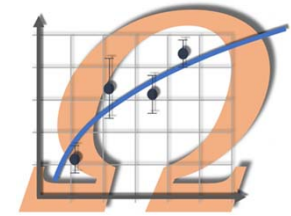
Wahrsch. \* Messwerte = Chauv. K.

**Ergebnis > 0,5 = OK**

- **Berechnung einmalig!**
- Mehrfache Berechnungen müssen verhindert werden!

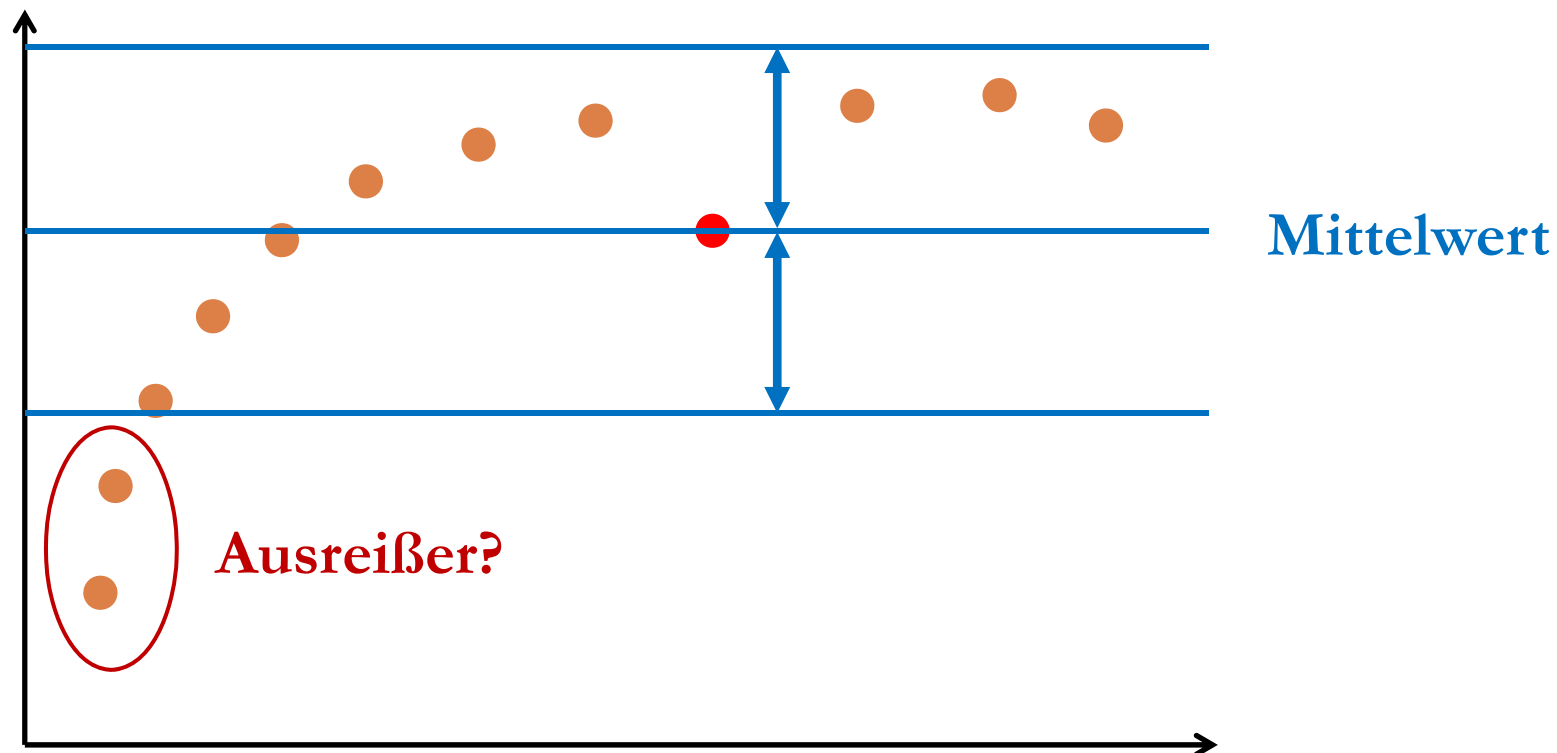
# Behandlung von Ausreißern

## Chauvenetsches Kriterium



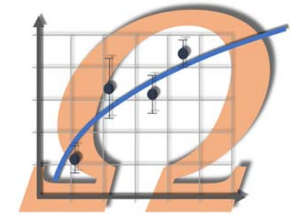
22

- Probleme durch Mittelwertbildung



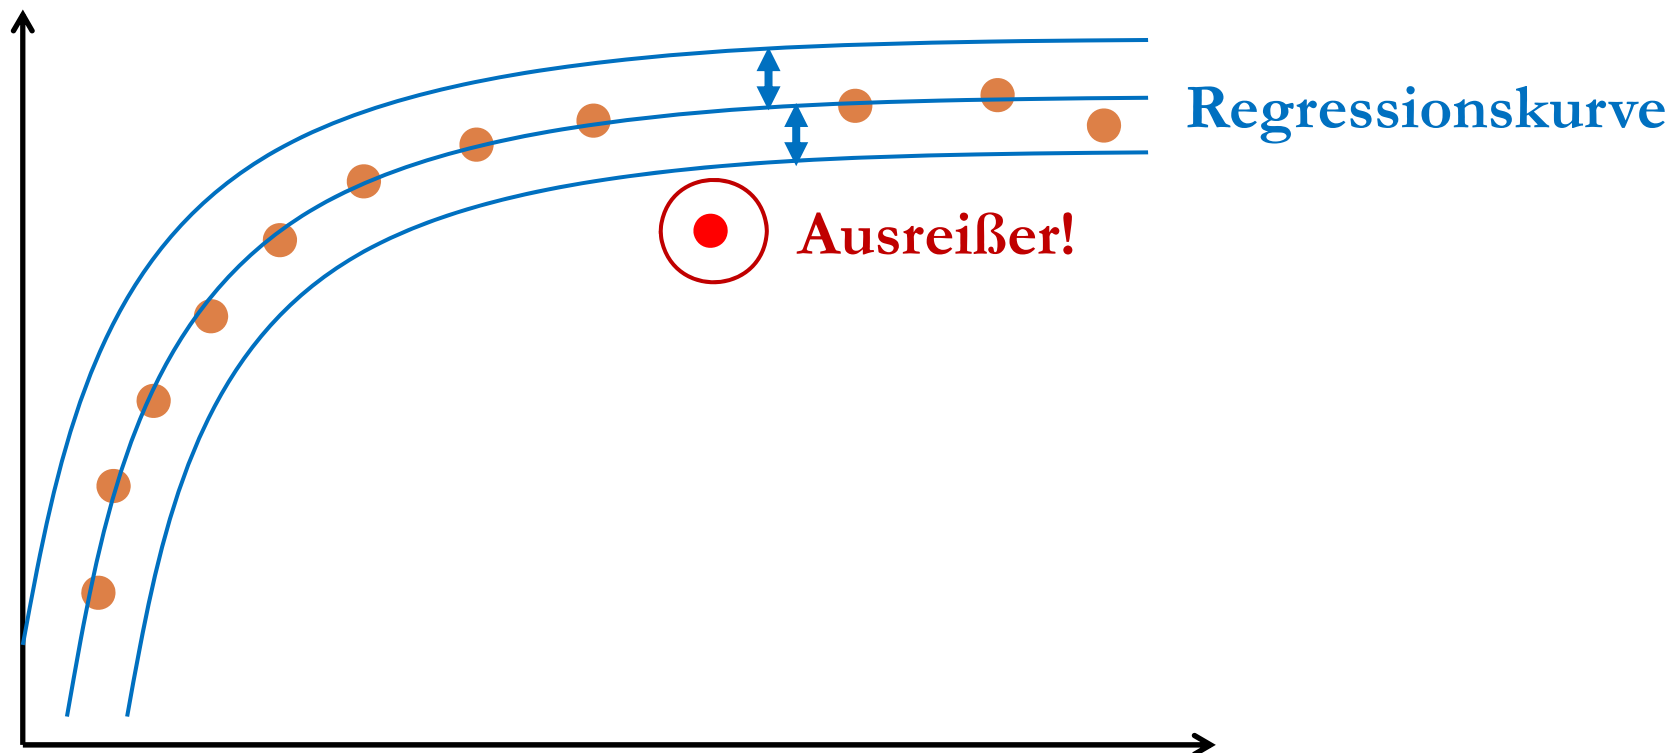
# Behandlung von Ausreißern

## Chauvenetsches Kriterium



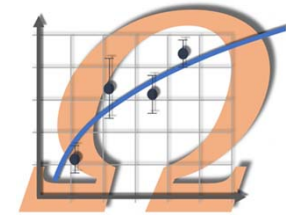
23

- Probleme durch Mittelwertbildung



# Softwareengineering

## Test & Validierung

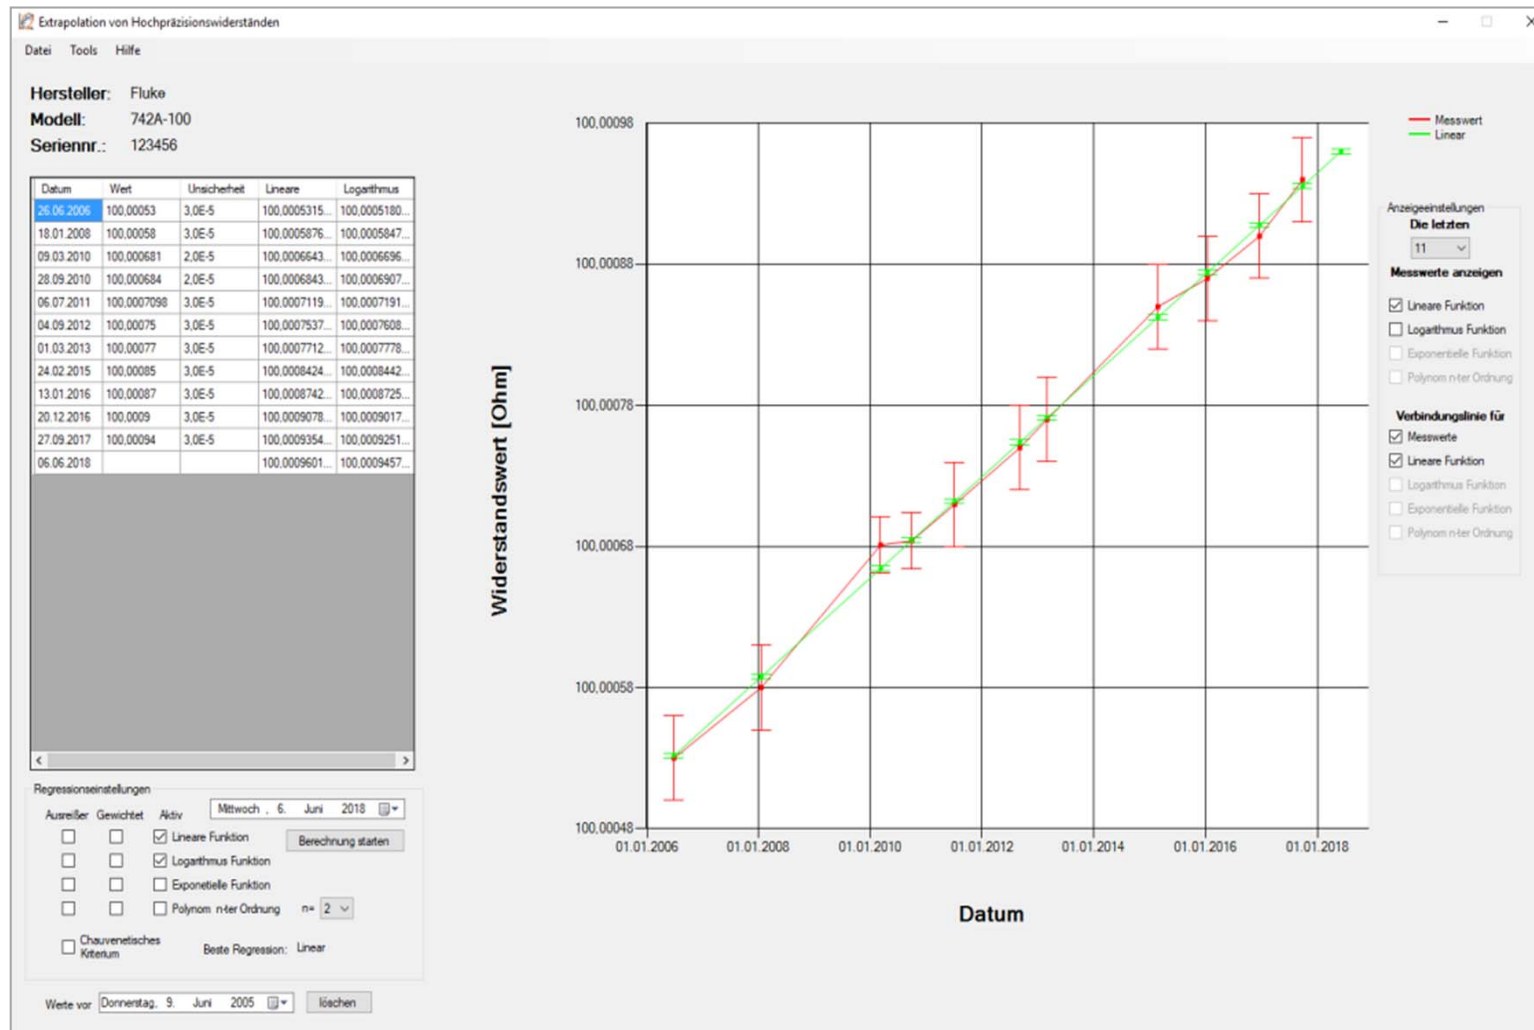
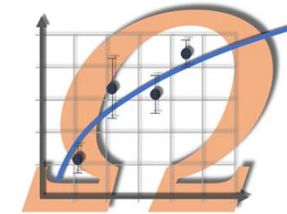


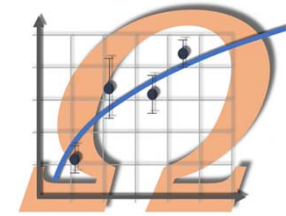
24

- Konstante Code-Reviews
- Tests mit Trainingsdaten
- Codeüberdeckung feststellen (C0)
  
- Vergleichsrechnungen mit
  - ▣ Vorenthaltenen Messdaten
  - ▣ Vergleich mit Kalibrierungen
  - ▣ Betatest beim Kunden
- Übereinstimmung prüfen  
( $E_N$ -Werte von ca. 0,1)

```
963     delta = delta + 1
964     'Untere Grenze
965     minGerundet = (Math.Round(CDbl(CInt(maxGer
966     Catch ex As Exception
967     End Try
968     End If
969     Dim YachsenBereichDbl As Double = (max - min)
970
971
972     'Min/Max-Werte für Y-Achse schreiben
973     If change_max Then
974         Chart1.ChartAreas("ChartArea1").Axes(1).Maximu
975     Else
976         Chart1.ChartAreas("ChartArea1").Axes(1).Maximu
977     End If
```

$$E_N = \frac{R_{\text{Kalibrierung}} - R_{\text{Regression}}}{\sqrt{U(R_{\text{Kalibrierung}})^2 + U(R_{\text{Regression}})^2}}$$





## □ Features:

### ▣ Regressionen

- Linear
- Polynom (bis 6. Ordnung)
- Logarithmisch
- Exponentiell

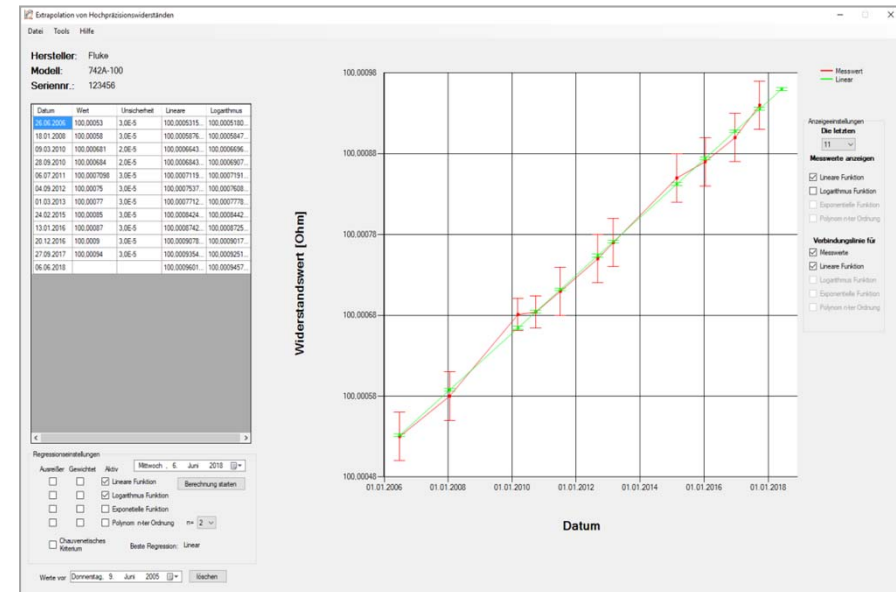
### ▣ Chauvenetsches Kriterium

- Traditionell
- Regressionsbezogen

### ▣ Gewichtung nach Unsicherheiten

### ▣ Dokumentation der Extrapolation in XML-Datei

### ▣ Verwendet .net Framework 4.5.2



Besuchen sie uns unter [www.mymetrologylab.de](http://www.mymetrologylab.de)

# Vielen Dank für Ihr Interesse!

Tobias Baisch, Sebastian Kuhls, Christian Rohrig, Norbert Stadter

## Fragen?

