

# Prognoseverfahren für Leistungstrends in der PKV

Dr. Markus Knappitsch (comma soft AG)  
Alexander Krauskopf (Central Krankenversicherung AG, Köln)



DAV

DEUTSCHE  
AKTUARVEREINIGUNG e.V.

qx-Club, 02.05.2017

# Agenda

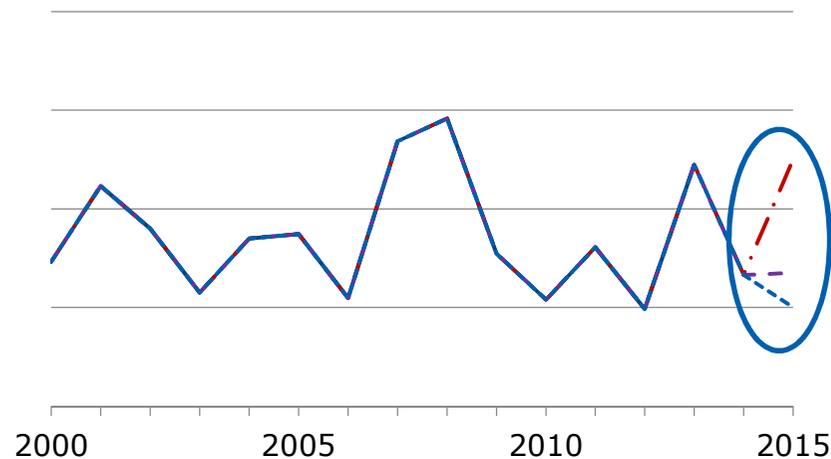
- Motivation: Bedeutung der Leistungstrends in der PKV
- Machine Learning mit künstlichen neuronalen Netzen
- ARMA-Modell aus der Zeitreihenanalyse
- Gegenüberstellung der Ergebnisse der unterschiedlichen Verfahren
- Stochastische Modellierung und Anwendungen in der Praxis
- Fazit



## Motivation: Leistungstrends und deren Prognose

## Bedeutung der Leistungstrends in der PKV

Möglicher Verlauf eines Leistungstrends  
in einem PKV-Portfolio



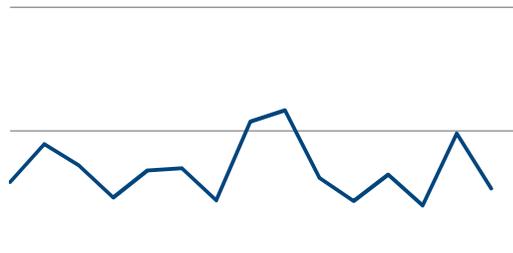
- Leistungstrends in der PKV können sehr volatil sein
- entscheidend für die Durchführung einer Beitragsanpassung (→ Schaden-AF)
- Festlegung des Anpassungsmaßes von großer Bedeutung für zukünftige Überschüsse und späteren Anpassungsbedarf

**→ Ziel: „Gute“ Prognose der Leistungstrends für die Folgejahre**

# Maschinelles Lernen zur Prognose von Leistungstrends?

## Maschinelles Lernen

Regressionsbäume  
Support Vector Machines  
Random Forests  
Recall  
Fuzzy Forecast  
Neuronale Netze  
Advanced Analytics  
Clusteranalyse  
Precision



## Klassische Statistik

Schätzer  
Parameter  
GLM  
ARMA Modelle  
Kennzahlen  
Zeitreihenanalyse  
Lineare Regression



Statistisches Lernen und klassische Statistik bieten verschiedene Sichtweisen auf unser Zeitreihenanalyseproblem.

## Leistungstrends in der PKV: ein Zeitreihenanalyseproblem?

Untersuchte Verfahren zur Prognose der Leistungstrends:

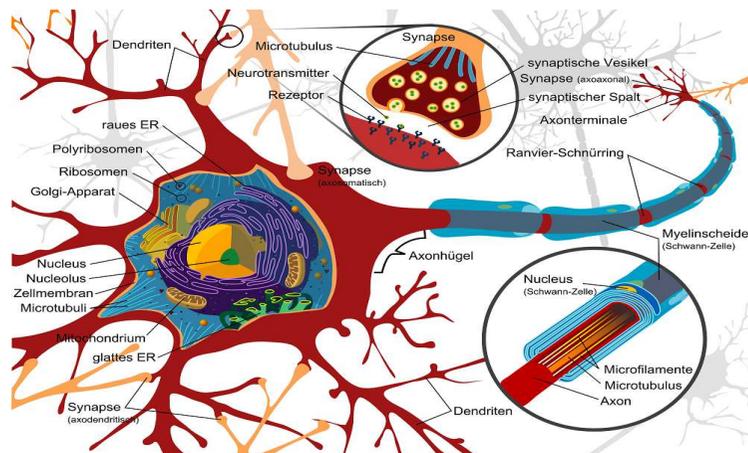
- Klassische Schätzverfahren (lineare Regression)
- **Zeitreihenanalyse mit künstlichen neuronalen Netzen (KNN)**
- Fuzzy-Zeitreihenanalyse (Fuzzy-ARMA)
- **Autoregressive Prozesse (ARMA)**



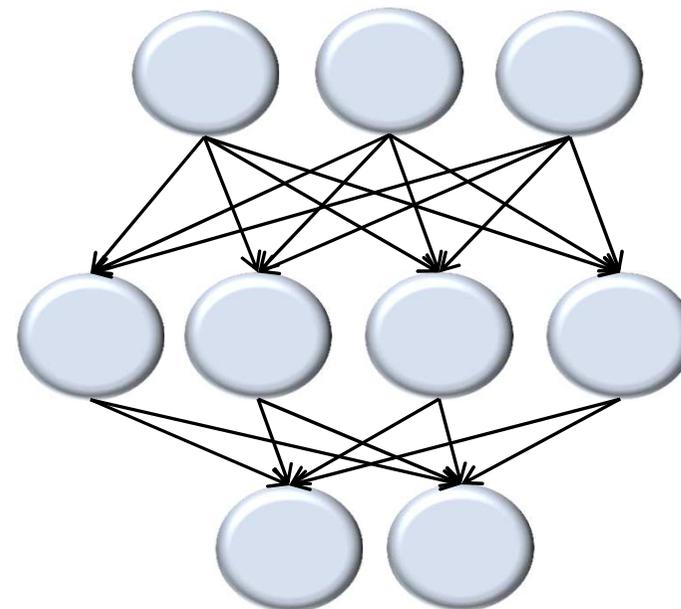
# Künstliche Neuronale Netze

# Künstliche neuronale Netze

- Netze künstlicher Neuronen haben Ihre Anfänge in den 1940er Jahren
- Werden zur Mustererkennung genutzt

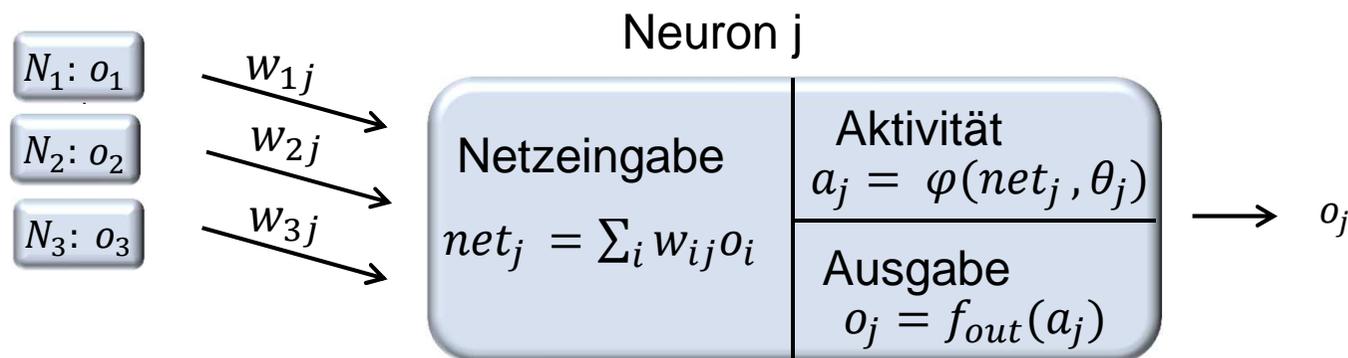


[https://upload.wikimedia.org/wikipedia/commons/thumb/d/d6/Complete\\_neuron\\_cell\\_diagram\\_cell\\_diagram\\_de.svg/2000px-Complete\\_neuron\\_cell\\_diagram\\_de.svg.png](https://upload.wikimedia.org/wikipedia/commons/thumb/d/d6/Complete_neuron_cell_diagram_de.svg/2000px-Complete_neuron_cell_diagram_de.svg.png)



## Schema eines künstlichen Neurons

Jedes Neuron bündelt eingehende Signale und gibt ggf. ein Output Signal weiter.

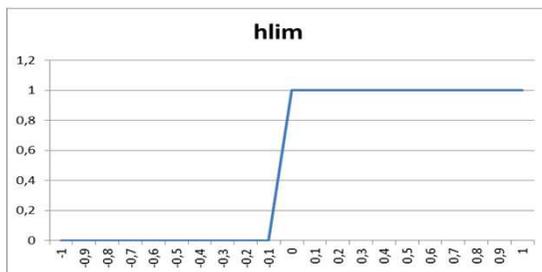


# Aktivierungsfunktionen künstlicher Neuronen

Beispiele für die Aktivierungsfunktionen:

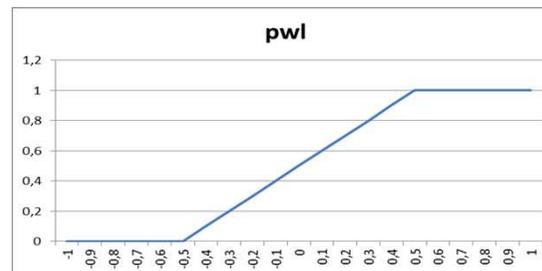
Sprungfunktion

$$\varphi^{\text{hlim}}(x) = \begin{cases} 0, & \text{wenn } x \leq 0 \\ 1, & \text{wenn } x > 0 \end{cases}$$



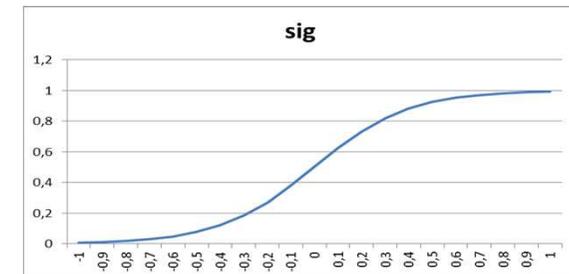
Stückweise linear

$$\varphi^{\text{pwl}}(x) = \begin{cases} 1, & \text{für } x \geq 0,5 \\ x + 0,5, & \text{für } -0,5 < x < 0,5 \\ 0, & \text{für } x \leq -0,5 \end{cases}$$



Sigmoidal

$$\varphi^{\text{sig}}(x) = \frac{1}{1 + e^{-ax}}$$



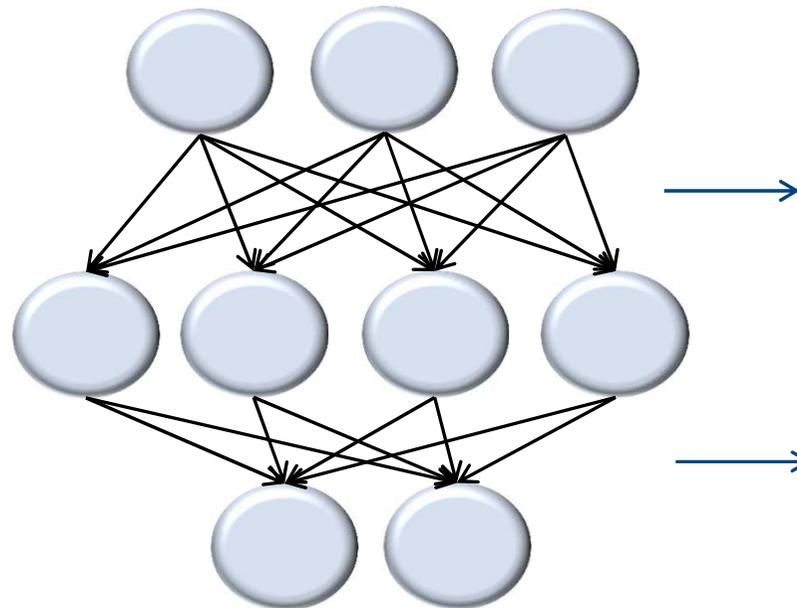
# Netztopologien: vom einzelnen Neuron zum Netz

Wie werden Neurone zu einem Netz verschaltet?  
 Hier: mehrschichtiges Feed-Forward Netz

Eingabeschicht

Verborgene  
Schicht

Ausgabeschicht



Gewichte

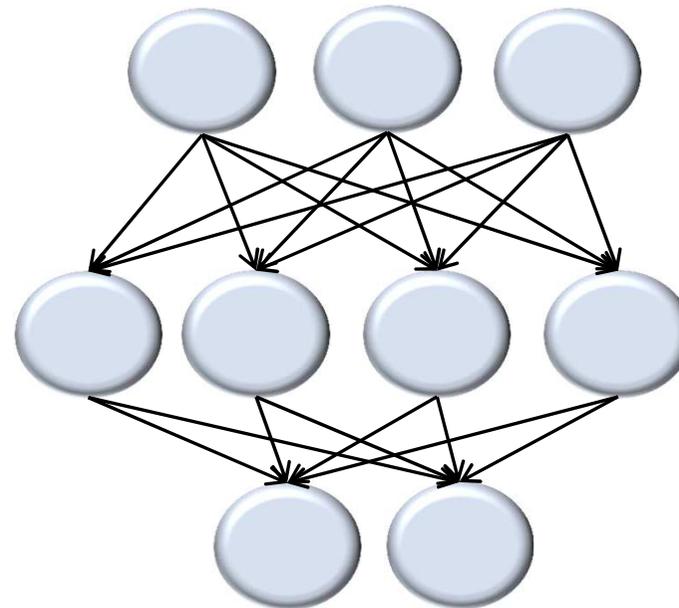
$$\begin{pmatrix} w_{11}^1 & w_{12}^1 & \dots \\ w_{21}^1 & w_{22}^1 & \dots \\ \vdots & \vdots & \ddots \end{pmatrix}$$

$$\begin{pmatrix} w_{11}^2 & w_{12}^2 & \dots \\ w_{21}^2 & w_{22}^2 & \dots \\ \vdots & \vdots & \ddots \end{pmatrix}$$

## Wie lernt ein neuronales Netz?

Denkbare Modifikationen, um ein KNN „lernen“ zu lassen:

- Neue Verbindungen schaffen
- Alte Verbindungen löschen
- Verbindungsgewichte ändern
- Neuronenfunktionen ändern
- Schwellenwerte ändern
- Neue Neuronen erzeugen
- Alte Neuronen löschen



# Lernen über Backpropagation

- Idee: Beschreibe Qualität der I/O-Abbildung durch ein Fehlerfunktional und minimiere dies über ein Gradientenverfahren:

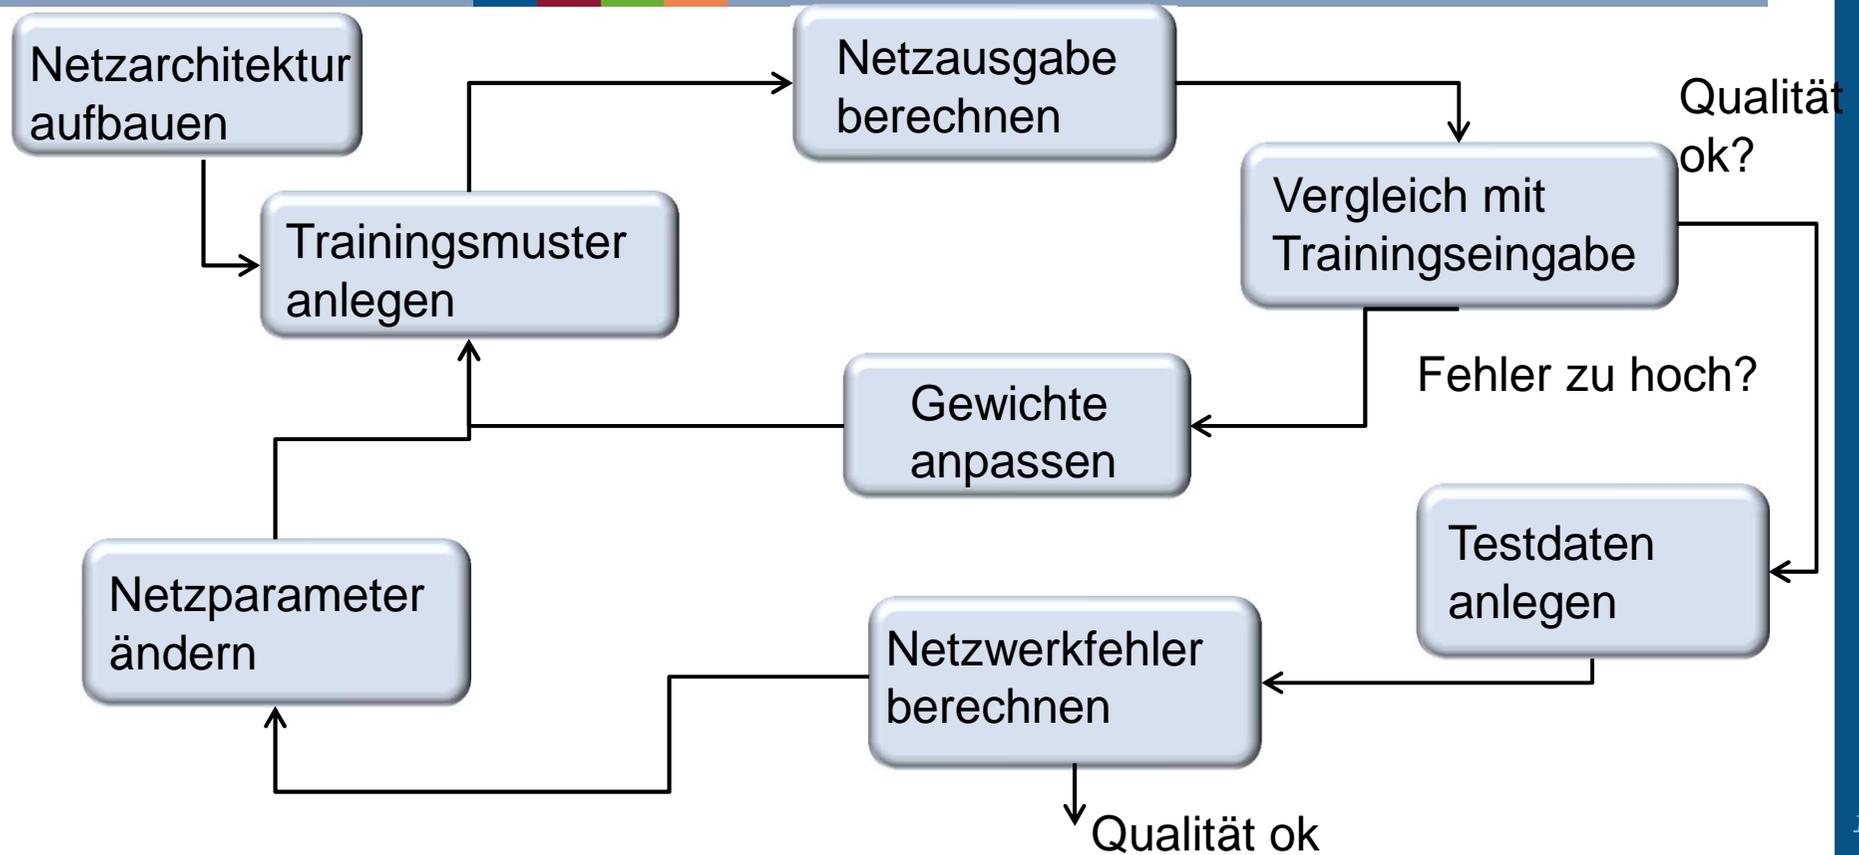
$$E = \frac{1}{2} \sum_i (t_i - o_i)^2 \quad \xrightarrow{\text{Minimierung nach Gewichten}} \quad \frac{\partial E}{\partial w_{i,j}} = \frac{\partial E}{\partial o_j} \frac{\partial o_j}{\partial net_j} \frac{\partial net_j}{\partial w_{i,j}}$$

$$\Delta w_{i,j} = -\beta \frac{\partial E}{\partial w_{i,j}} = \beta \delta_j x_i \quad \text{mit} \quad \delta_j = \begin{cases} \varphi'(net_j)(t_j - o_j) \\ \varphi'(net_j) \sum_l \delta_l w_{l,j} \end{cases}$$

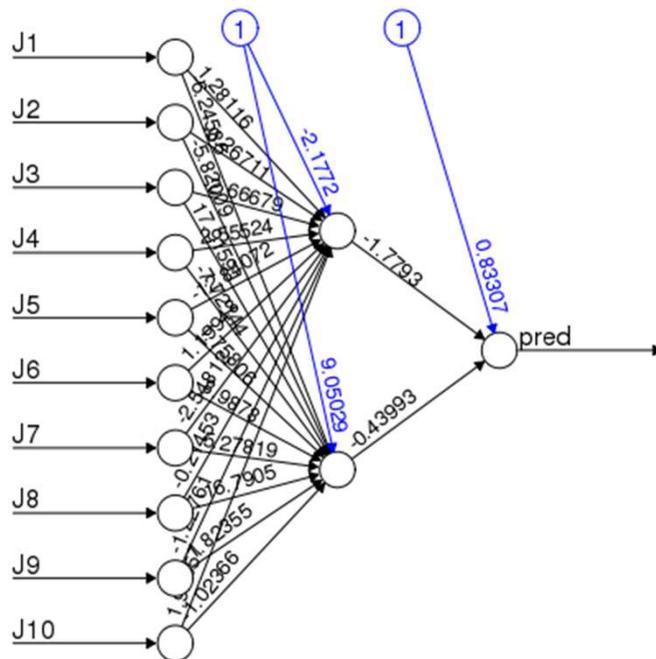
Update Formel:

$$w_{i,j}^{(neu)} = w_{i,j}^{(alt)} + \Delta w_{i,j}$$

# Trainings- und Testphase: wie lernt eine Maschine?



# Implementierung mit dem „neuralnet“- Package in R



```
# Trainings- Testdaten zufaellig waehlen
index <- sample(1:nrow(data),round(0.75*nrow(data)))
train <- data[index,]
test <- data[-index,]
```

```
# Daten normalisieren
maxs <- apply(data, 2, max)
mins <- apply(data, 2, min)
scaled <- as.data.frame(scale(data, center = mins, scale = maxs - mins))
train_ <- scaled[index,]test_ <- scaled[-index,]
```

```
#NN trainieren
library(neuralnet)n <- names(train_)
f <- as.formula(paste("pred ~", paste(n[!n %in% "pred"], collapse = " + ")))
nn <- neuralnet(f,data=train_,hidden=2,linear.output=T)
```

```
#NN visualisieren
plot(nn)
```

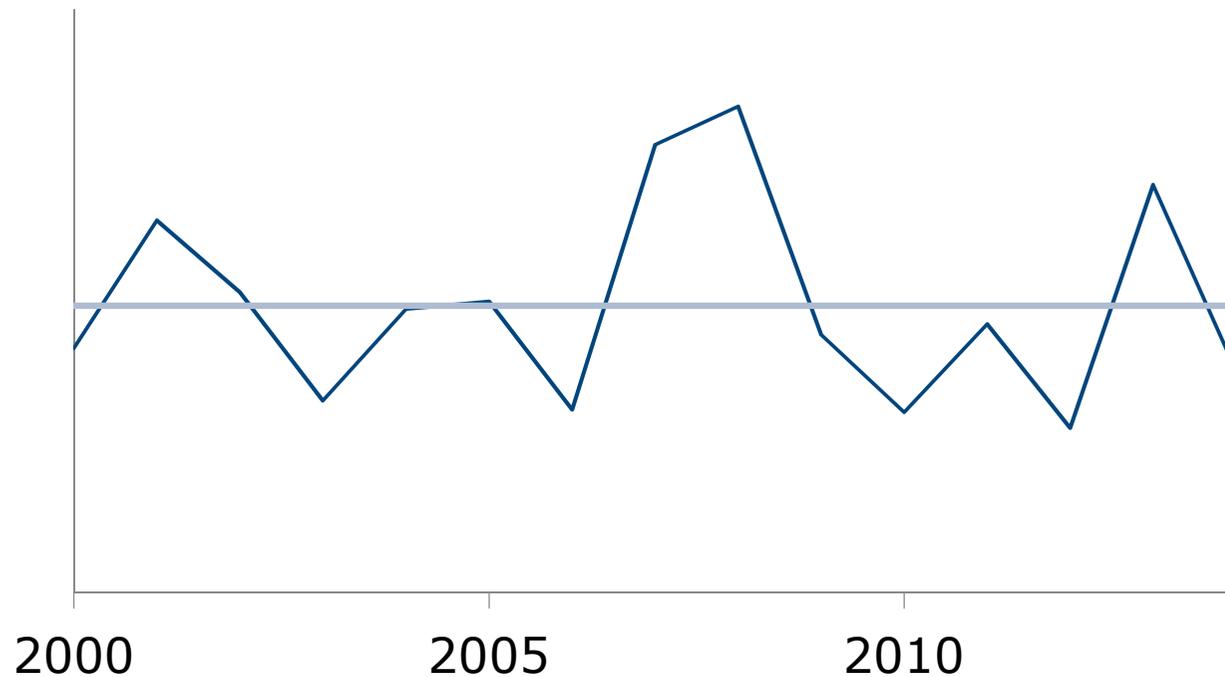
```
# Model fit
pr.nn <- compute(nn,test_[,1:10])
pr.nn_ <- pr.nn$net.result*(max(data$pred)-min(data$pred))+min(data$pred)
test.r <- (test_$pred)*(max(data$pred)-min(data$pred))+min(data$pred)
MSE.nn <- sum((test.r - pr.nn_)^2)/nrow(test_)
```

```
# Fehler vergleichen
print(paste(MSE.lm,MSE.nn))
```



# ARMA-Modelle

## Mögliche Struktur eines jährlichen Leistungstrends



- Beobachtungswerte schwanken um langfristigen Mittelwert
- Schätzungen mit Mittelwert und linearen Trends können zu z. T. erheblichen Schätzfehlern führen
- **starke Ausreißer lassen sich nur über Verteilungsaussagen prognostizieren**

## Leistungstrend als stochastischer Prozess

- Leistungstrend wird als **stochastischer Prozess** angesehen  $\{I_t\}_{t \in \mathbb{Z}}$
- Annahme sei (zunächst), dass  $I_t$  **stationär** ist, d. h. es gelten:
  - (i)  $E[I_t] = \mu$  *konstant*
  - (ii)  $Var[I_t] < \infty$  für alle  $t \in \mathbb{Z}$
  - (iii)  $Cov[I_s, I_t] = Cov[I_{s+h}, I_{t+h}]$  für alle  $s, t, h \in \mathbb{Z}$  (**Autokovarianz**)
- Leistungstrend streut um einen langfristigen konstanten Mittelwert  $\mu$
- durch die Autokovarianz wird die „*innere Abhängigkeitsstruktur*“ des Prozesses beschrieben („Wie hängt der Wert im Jahr  $t$  vom Wert in  $t-1$ ,  $t-2$ , ... ab?“)
- die Autokovarianz des Prozesses hängt nur vom Abstand der Beobachtungszeiträume, aber nicht vom konkreten Beobachtungszeitpunkt ab

## Autoregressiver Prozess AR(1)

- **Idee:** Leistungstrend als **Mean-Reversion-Prozess** ansehen
- Modellierung der jährlichen Veränderung des Leistungstrends  $I_t - I_{t-1}$

$$I_t - I_{t-1} = \underbrace{a \cdot (\mu - I_{t-1})}_{\text{Drift-Komponente}} + \underbrace{Z_t}_{\text{Diffusion}}$$

*Drift-Komponente:*

$\mu$  = langfristiger (beobachteter) Mittelwert des Leistungstrends

$a$  = Faktor für die „Rückkehrgeschwindigkeit“ zum langfristigen Mittelwert

*Diffusion:*

allgemein:  $Z_t \sim \text{WN}(0, \sigma^2)$  (White-Noise-Prozess)

→ stochastische Komponente des Leistungstrends (repräsentiert die Volatilität der Werte)

## Prognose des Leistungstrends

Schätzer für den Leistungstrend im Folgejahr:

Wegen  $E[Z_t]=0$  ergibt sich folgende **Best-Estimate-Schätzung**:

$$E[I_t | I_{t-1} = i_{t-1}] = i_{t-1} + a \cdot (\mu - i_{t-1})$$

D. h. **nach Festlegung der Modellparameter** kann der erwartete Leistungstrend im Folgejahr geschätzt werden.

Einbindung der stochastischen Komponente ermöglicht auch die Angabe der gesamten Verteilungsfunktion des Leistungstrends im Folgejahr / in den Folgejahren.

## Schätzung der Modellparameter

$$\mu = \hat{\mu}$$

$$a = 1 - \hat{\rho}(1)$$

$$\sigma^2 = \hat{\gamma}(0) \cdot (1 - (1 - a)^2)$$

### Yule-Walker-Schätzer

- gegeben seien T Beobachtungswerte  $I_1, \dots, I_T$  des Leistungstrends

- Schätzer für Mittelwert:  $\hat{\mu} = \frac{1}{T} \cdot \sum_{t=1}^T I_t$

- Schätzer für die Autokovarianz:  $\hat{\gamma}(h) = \frac{1}{T} \cdot \sum_{t=1}^{T-h} (I_t - \hat{\mu}) \cdot (I_{t+h} - \hat{\mu})$

- Schätzer für die Autokorrelation:  $\hat{\rho}(h) = \frac{\hat{\gamma}(h)}{\hat{\gamma}(0)}$



## Vergleich der Prognosegüte

## Vergleich der Prognosegüte

### **Methodik zur Feststellung der Prognosegüte:**

Schätzung der Jahrestrends der letzten zehn Jahre unter Verwendung der im jeweiligen Prognosejahr verfügbaren Daten

### **Kennzahlen:**

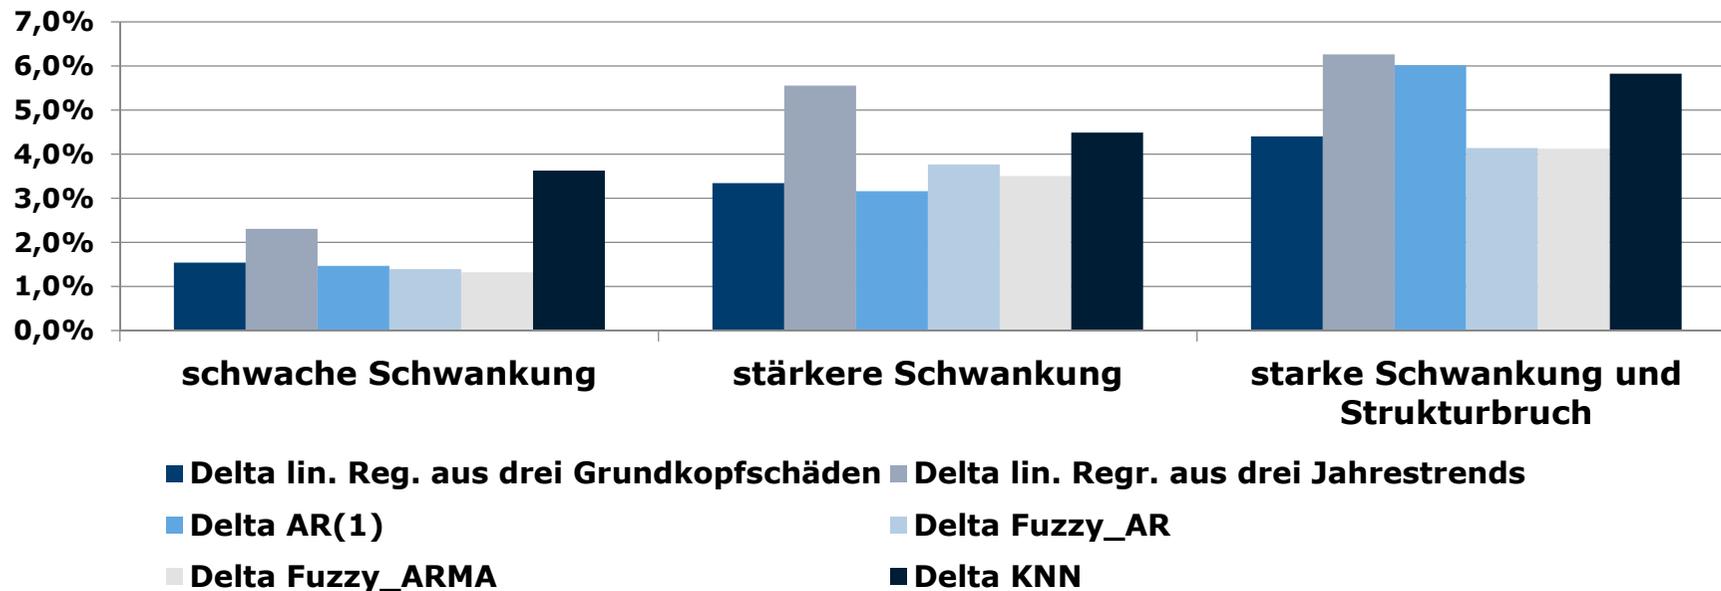
- jährliche Abweichung der Prognosewerte vom tatsächlichen Leistungstrend
- Mittelwert und RMSE (= Root-Mean-Square-Error) der Schätzfehler in den zehn Prognosejahren

### **Prognosegüte hängt stark von der Struktur der Zeitreihe ab**

- Leistungstrends mit schwacher Schwankung
- Leistungstrends mit höherer Schwankung
- Leistungstrends mit starker Schwankung und Strukturbruch

# Vergleich der Prognosequalität der Methoden

## Vergleich der RMSE der Abweichungen aus 10 Prognosejahren





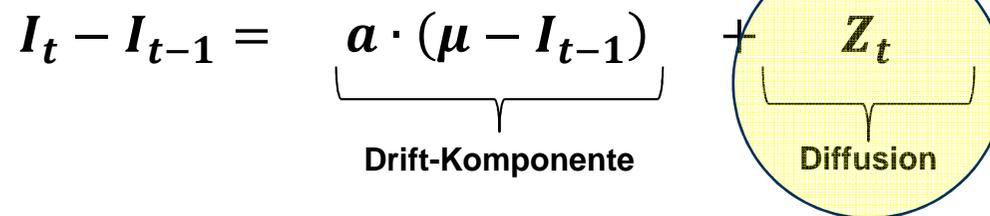
# Stochastische Modellierung und ihre Anwendungen in der Praxis

## Wozu stochastische Modellierung?

- untersuchte statistische Verfahren lieferten mehr oder weniger gute Ergebnisse, jedoch **keine „exakte“ Prognose**
- Problem liegt nicht an den Verfahren, sondern an den mitunter **starken Schwankungen** der jährlichen Leistungstrends
- Punktschätzer ergänzen um eine Aussage zu einer möglichen **Bandbreite** der zukünftigen Leistungstrends
- **Idee: stochastische Modellierung** der zukünftigen Leistungstrends und Ableitung der Verteilungsfunktion für unterschiedliche Unternehmenskennzahlen

## Ansatz für eine stochastische Modellierung

- **Idee:** Leistungstrend als **Mean-Reversion-Prozess** ansehen
- Modellierung der jährlichen Veränderung des Leistungstrends  $I_t - I_{t-1}$

$$I_t - I_{t-1} = \underbrace{a \cdot (\mu - I_{t-1})}_{\text{Drift-Komponente}} + \underbrace{Z_t}_{\text{Diffusion}}$$


*Drift-Komponente:*

$\mu$  = langfristiger (beobachteter) Mittelwert des Leistungstrends

$a$  = Faktor für die „Rückkehrgeschwindigkeit“ zum langfristigen Mittelwert

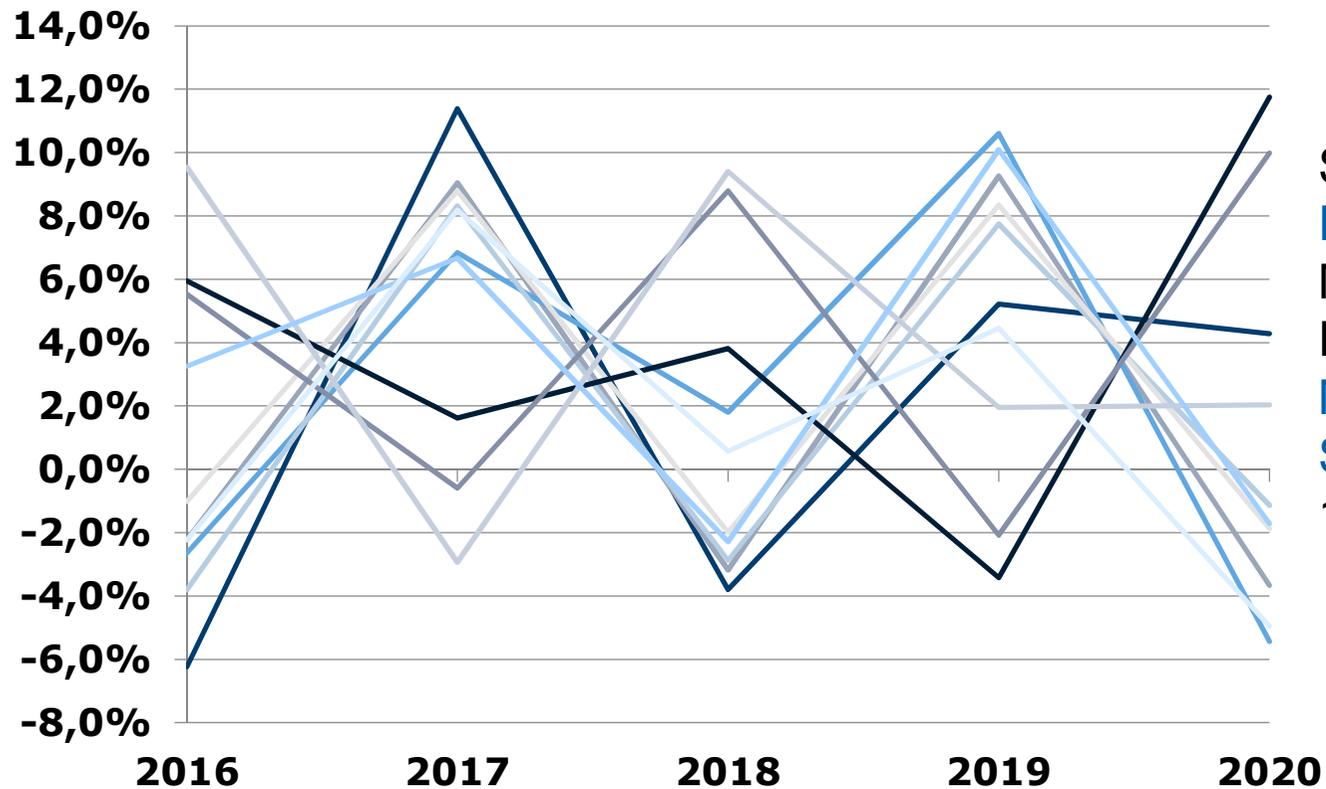
*Diffusion:*

allgemein:  $Z_t \sim \text{WN}(0, \sigma^2)$  (White-Noise-Prozess)

→ stochastische Komponente des Leistungstrends (repräsentiert die Volatilität der Werte)

→ hier:  $Z_t \sim \text{N}(0, \sigma^2)$

## Simulation möglicher zukünftiger Leistungstrends



Simulation möglicher Realisierungen des Mean-Reversion-Prozesses mittels Monte-Carlo-Simulation (z. B. 1.000 Pfade)

## Mögliche Anwendungen in der Praxis - Kalkulation

- Im Kalkulationsjahr  $t$  sind die tatsächlichen Grundkopfschäden  $G_i$  der Beobachtungsjahre  $i = t-3, t-2$  und  $t-1$  sowie der aktuelle rechnungsmäßige Grundkopfschaden  $G^{rm}$  bekannt
- Simulation von 1.000 Realisierungen des unbekanntem Grundkopfschadens im Jahr  $t+1$  gemäß

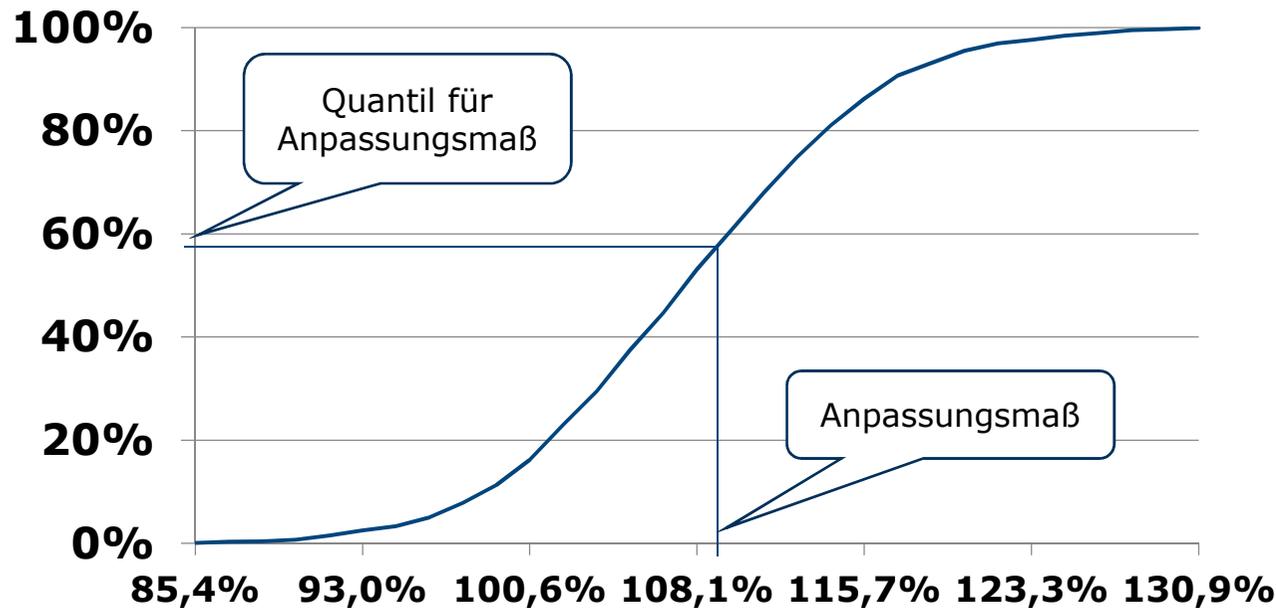
$$\hat{G}_{t+1,Pfad} = G_{t-1} \cdot (1 + i_{t,Pfad}) \cdot (1 + i_{t+1,Pfad})$$

- Erstellung der empirischen Verteilungsfunktion für die relative Abweichung

$$\widehat{VQ}_{t+1,Pfad} := \frac{\hat{G}_{t+1,Pfad}}{G^{rm}} \quad \rightarrow \quad \text{Quantil als Maß für die Sicherheit des aktuellen Anpassungsmaßes}$$

## Mögliche Anwendungen in der Praxis - Kalkulation

### Verteilungsfunktion für VQ im Folgejahr



rel. Abweichung des tats. GKS in t+1 vom aktuellen rechnungsmäßigen GKS

#### Perspektive 1:

Festlegung des Anpassungsmaßes nach den üblichen Verfahren und Betrachtung der gewählten Sicherheit

#### Perspektive 2:

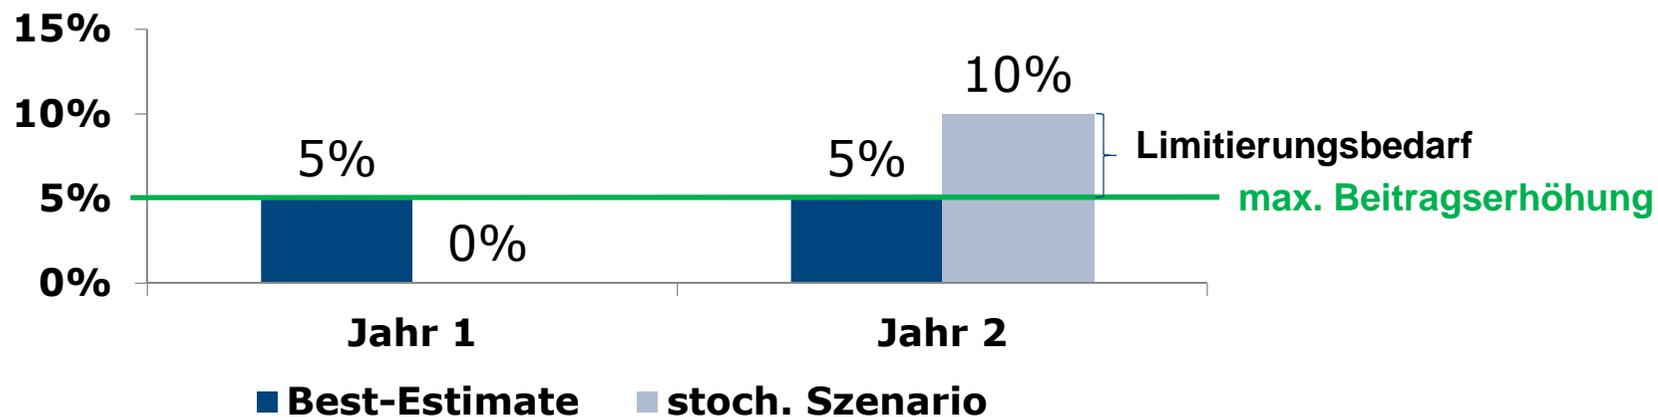
Auswahl des Anpassungsmaßes als Quantil abhängig von gewünschtem Sicherheitsniveau

## Mögliche Anwendungen in der Praxis - Unternehmensplanung

- Unternehmensplanung beschreibt i. d. R. die erwartete Entwicklung der wesentlichen Unternehmenskennzahlen unter Verwendung von **Best-Estimate-Schätzern** für die Berechnungsparameter
  - die zukünftige Leistungsentwicklung hat wesentlichen Einfluss auf
    - Anpassungsausmaß (Zeitpunkt und Höhe)
    - Überschuss-Situation (insb. Möglichkeit einer Rechnungszins-Senkung)
    - Entwicklung der RfB (Entnahmebedarf und Zuführung)
- **Reicht die Betrachtung eines Best-Estimate-Szenarios für die zukünftige Leistungsentwicklung aus?**

## Mögliche Anwendungen in der Praxis - Unternehmensplanung

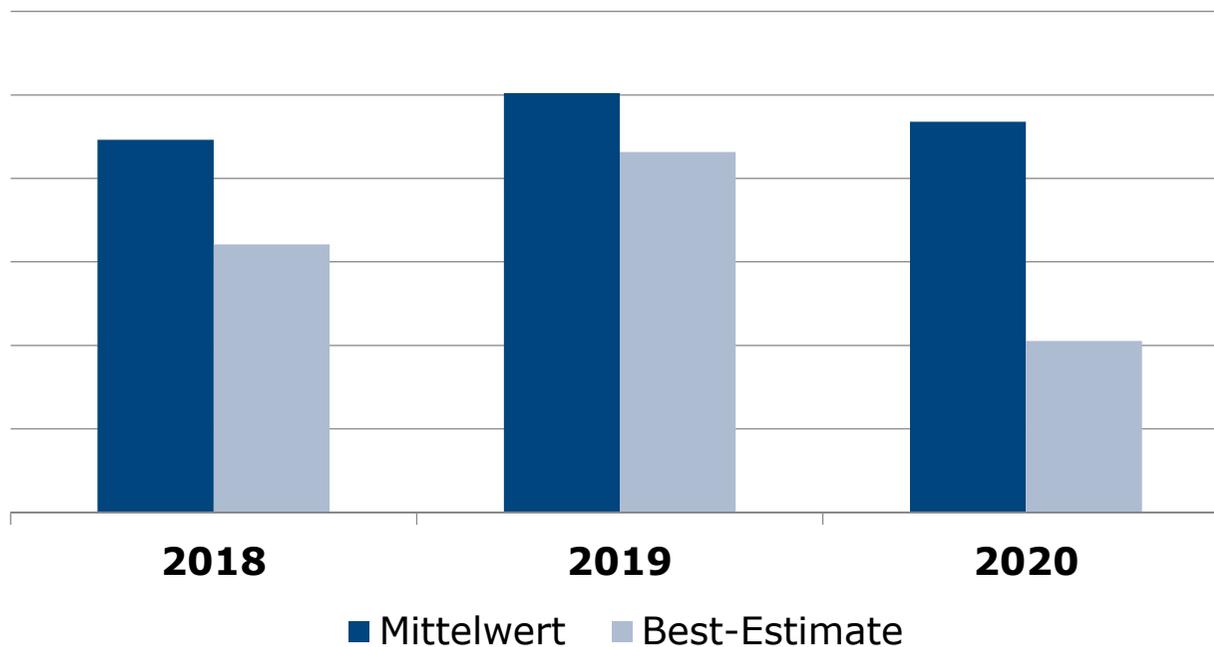
### jährlicher BAP-Bedarf



- in beiden Szenarien ergibt sich derselbe durchschnittliche BAP-Bedarf
  - aber: ein Limitierungsbedarf wird erst durch die Berücksichtigung einer Schwankung des BAP-Bedarfs deutlich
- ein reiner Best-Estimate-Ansatz kann zu einer Fehleinschätzung des RfB-Mittelbedarfs führen

## Mögliche Anwendungen in der Praxis - Unternehmensplanung

### Vergleich der RfB-Entnahme aus Mittelwert der Szenarien und Best-Estimate-Szenario



- mehrjährige Simulation der BAP und der zugehörigen RfB-Entnahme auf Basis stochastischer Szenarien für die Leistungsentwicklung und des Best-Estimate-Szenarios
- Mittelwert der stoch. Szenarien kann sich deutlich vom Best-Estimate unterscheiden



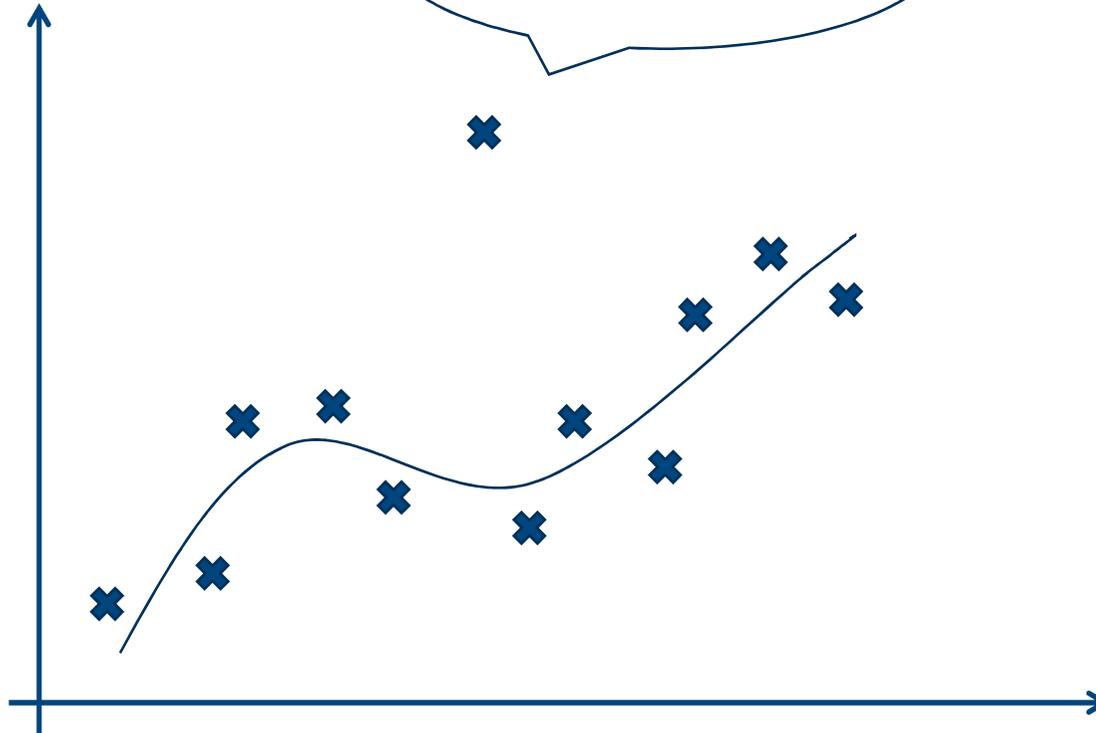
# Fazit

## Fazit

- Es wurden verschiedene Verfahren zur Prognose von Leistungstrends in Bezug auf Prognosequalität und Handhabbarkeit verprobt
- Stochastische Schwankungen in den Kostentrends überlagern strukturelle Effekte und machen Prognosen unabhängig vom Verfahren schwierig
- Unsere Erfahrungen bzgl.:
  - Lineare Regressionsmodelle
  - Künstliche neuronale Netze
  - ARMA- Modelle
  - Fuzzy-Forecast Ansätze
- Ergänzung der Punktschätzern durch stochastische Modellierung und Aussagen über die Verteilungsfunktion der Leistungstrends liefert zusätzliche Erkenntnisse



Euer Modell ist  
Käse!



Vielen Dank für Ihre Aufmerksamkeit.