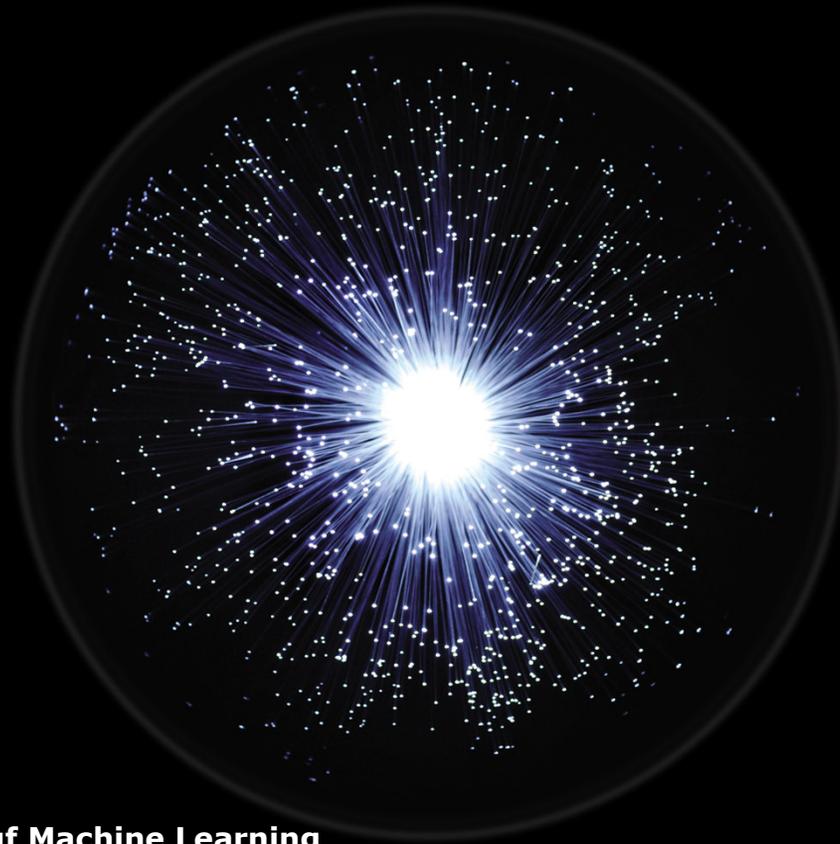


**Deloitte.**



**Branchensimulationsmodell trifft auf Machine Learning**

qx-Club  
Köln, den 05.05.2020

Johannes Fabrega, B&W Deloitte; Prof. Dr. Christian Weiß, Hochschule Ruhr West, B&W Deloitte

# Einführung

Herausfordernde Fragen in Risikomanagement und Aktuariat der deutschen Versicherer

	<p>US Corporate Bonds versprechen derzeit eine vergleichsweise hohe Rendite. Hätte ein Investment starke Auswirkungen auf unser Risikoprofil?</p>		<p>Was für eine Aktienquote sollen wir langfristig anstreben um von Diversifikationseffekten maximal zu profitieren?</p>
	<p>Wie wäre es, wenn wir die Duration unseres Bond Portfolios deutlich verlängern, sodass es besser zu unserem Passiv-Bestand passt?</p>		<p>Welche neue Geschäftsstrategie kann uns nachhaltig gegen das langandauernde Niedrigzinsumfeld wappnen?</p>
	<p>Wir kennen die Kapitalmarktsituation in drei Jahren noch nicht. Wie können wir in unserer Planung alle realistischen Szenarien einbeziehen?</p>		<p>Unsere Schätzung für die Solvenzquote zum Jahresende lag weit entfernt vom tatsächlichen Ergebnis. Wie können wir das in Zukunft verbessern?</p>

**Die Suche nach zufriedenstellenden Antworten führt zu neuartigen Lösungen.**

# Aktuarielle Risikomodelle

Aktuarielle Risikomodelle wie das **Branchen-simulationsmodell** (BSM) sind mächtige Tools für Analysen, etwa von Investmententscheidungen und Anlagestrategien, denn sie enthalten:

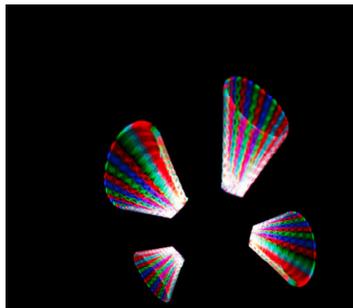
- die Kapitalanlagen
- die Versicherungsverträge
- Parameter für Management-Entscheidungen

## aber:

- Aktuarielle Risikomodelle sind extrem laufzeitintensiv und daher unflexibel.
- Jeder Berechnungslauf muss oft manuell eingerichtet werden und benötigt viele Simulationen.
  - **Budget reicht nur für einzelne Sensitivitäten.**

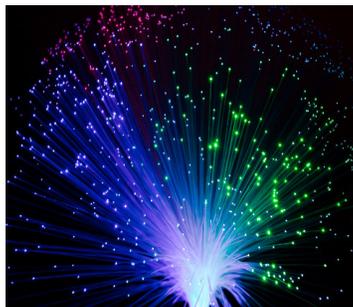
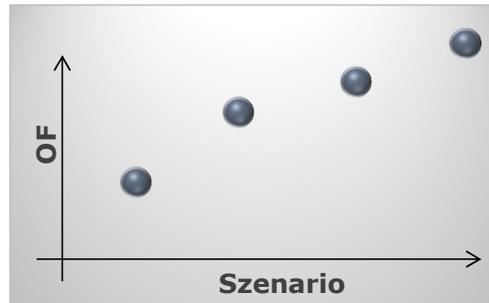


# Monte-Carlo-Ansatz



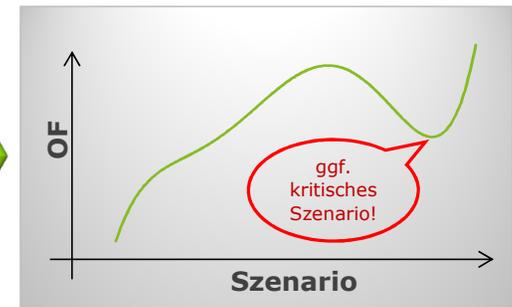
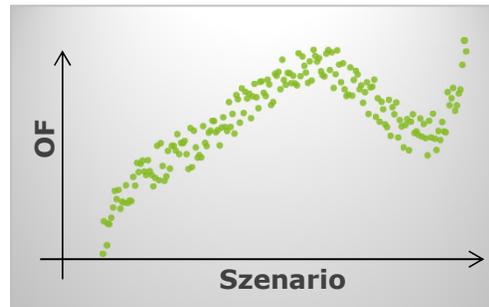
**Bislang:**

- Einzelne, isolierte Sensitivitäten
- Äußerst rechenintensiv
- Vollständige Modellberechnung für jede einzelne Sensitivität



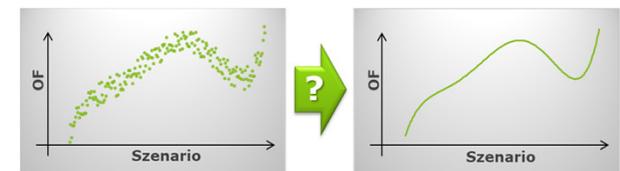
**Monte-Carlo-Ansatz:**

- Berücksichtigung von Aktiva, Passiva, Management-Strategien und Kapitalmarkt
- Beliebige Kombinationen von Parametern
- Einmalige Kalibrierung – instantane Auswertungen



# Herausforderndes Regressionsproblem

- **Ungenauigkeit** einzelner Fittingpunkte (Rauschen)
- **Wechselwirkungen** zwischen den Dimensionen des Parameterraumes
- **Komplexe Abhängigkeitsstruktur** (oft nicht glatt)
  - Konventionelle Ansätze liefern keine stabilen und präzisen Ergebnisse.



**Lösung:**  
**Moderne Machine Learning Algorithmen**



# Machine Learning Techniken (1/3)

Informationskriterium AIC

# Akaike Informationskriterium (AIC)

## Klassische Statistik

Schätze den **unbekannten Parameter einer bekannten Verteilung**, z.B. die Varianz einer normalverteilten Zufallsvariable

## SCR Schätzung

Schätze **die unbekannt Koeffizienten einer unbekannt approximierenden Funktion**, z.B. eines Polynoms

- Es sind also **zwei simultane Aufgaben** zu erledigen: Finde beste approximierende Funktion **und** gleichzeitig deren beste Koeffizienten
- Das **Akaike Informationskriterium AIC** vergleicht die Güte des Fits unterschiedlicher Modelle



Hirotugu Akaike (1927 – 2009)

Bildquelle:  
Wikipedia

# Mathematischer Hintergrund

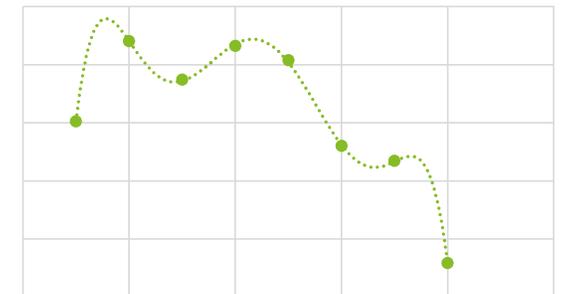
## Satz (Akaike, 1973):

Das AIC ist ein erwartungstreuer Schätzer für die **Kullback-Leibler Divergenz**, das heißt, es ist ein Maß dafür wie gut eine gegebene Funktion  $f$  mit  $k$  Parametern eine andere unbekannte Funktion  $g$  annähert. Sind die Fehler der Regression normalverteilt, so gilt

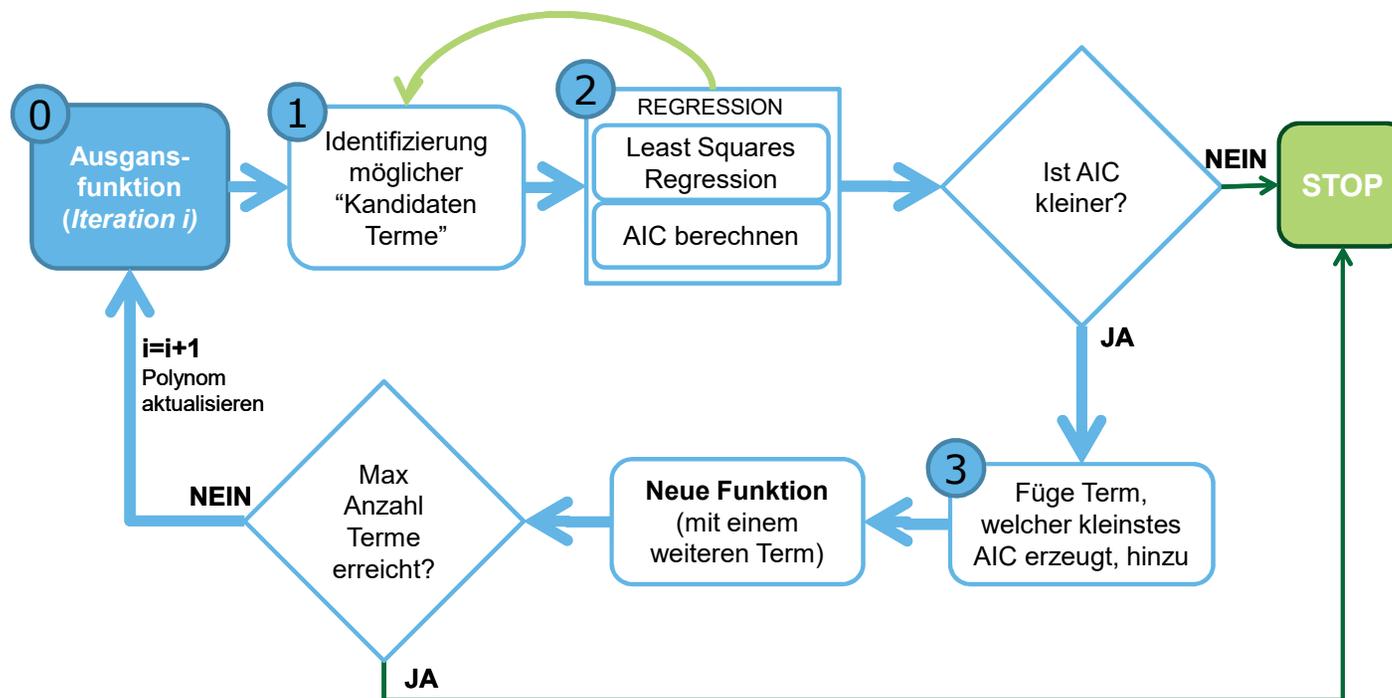
$$AIC = n \log \left( \frac{RSS}{n} \right) + 2k$$

- Der erste Term in AIC misst die Güte des Modelfits (je kleiner die Abweichung, desto kleiner AIC)
- Der zweite Term „bestraft“ komplexe Modelle (je mehr Parameter, desto größer AIC)

Overfitting



# Algorithmus zum Auffinden einer optimalen Funktion



- Teste jedes **"Kandidaten-Modell"**
- Der beste Term von den möglichen Kandidaten wird zur Funktion hinzugefügt
- **Multiple Regression** - jedes mal wird nur ein einziger weiterer Term hinzugefügt

# Machine Learning Techniken (2/3)

## Random Forests

# Random Forests

## Einführung

- Der Begriff *Random Forests* wurde 1999 von **Leo Breiman** geprägt.
- Es ist ein klassisches Verfahren des Machine Learnings, das insbesondere zu Zwecken der **Klassifizierung** und zur **Regression** eingesetzt wird.
- Beruht auf der Verknüpfung von mehreren **Entscheidungsbäumen**, die in einem zufälligen Lernprozess gewachsen sind (**random subspace method**).

## Vorteile

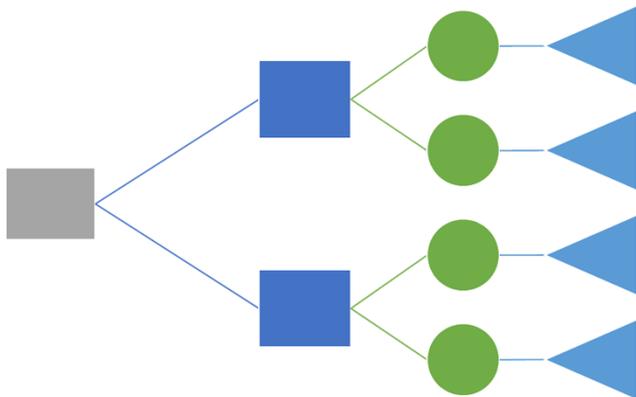
- **Geringer Zeitaufwand** für die Kalibrierung
- Es kann eine **sehr hohe Anzahl von Inputs** verwendet werden
- Als Ergebnis erhält man eine Einschätzung darüber, **welche Variablen besonders wichtig sind**



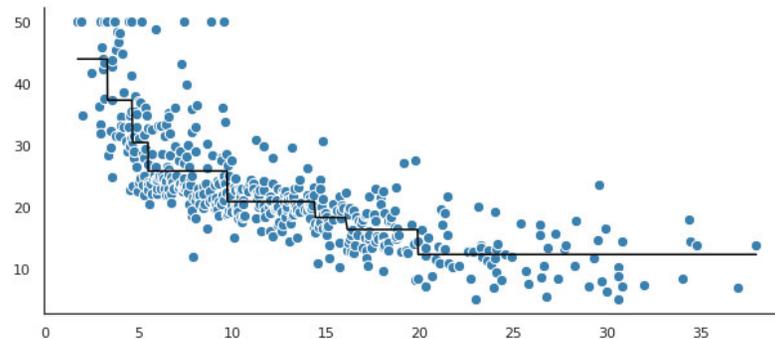
Leo Breiman (1928 – 2005)

Bildquelle:  
Wikipedia

# Entscheidungsbäume



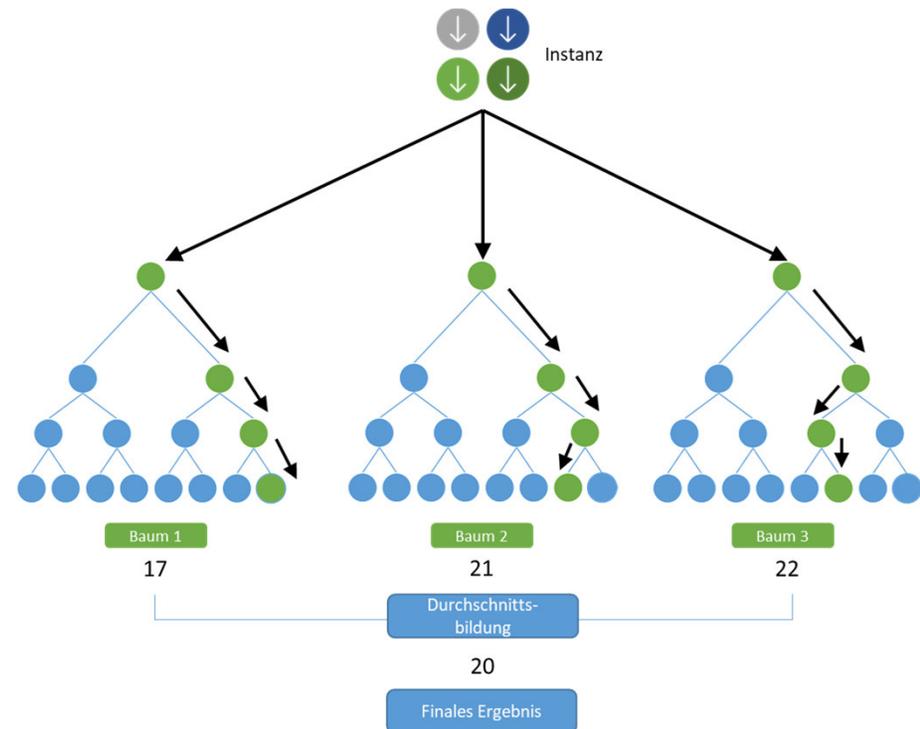
- Allgemein: Ein **Entscheidungsbaum** ist eine Abfolge von Tests auf ein mögliches Ergebnis, um am Ende eine Vorhersage zu machen.
- Wenn die Ausgabevariable Werte in einem Intervall annehmen kann, spricht man von einem **Regressionsbaum**
- Regressionsbäume können zur Lösung von Regressionsaufgaben eingesetzt werden



Quelle (bearbeitet): <https://towardsdatascience.com/https-medium-com-lorli-classification-and-regression-analysis-with-decision-trees-c43cdbc58054>12

# Ensemble Techniken

- Ein **Random Forest** verknüpft verschiedene Entscheidungsbäume
- Jeder einzelne Entscheidungsbaum macht eine eigene Vorhersage
- Die finale Vorhersage bei den Regressionsbäumen wird durch **Durchschnittsbildung** gemacht
- Die standardmäßig genutzte Ensemble Technik ist also **Bagging**, weil verschiedene Modelle parallel laufen
- Oft werden Random Forests mit der **Boosting**-Technik kombiniert



# Machine Learning Techniken (3/3)

## Neuronale Netze

# Neuronale Netze & Deep Learning

## Warren McCulloch & Walter Pitts, 1943

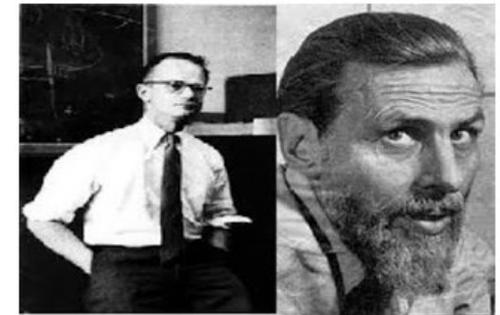
erste Idee für ein künstliches neuronales Netz, aus verknüpften elementaren Einheiten zur Berechnung logischer und arithmetischer Funktionen

## Frank Rosenblatt, 1958

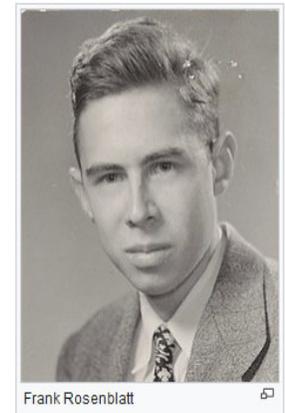
Neurocomputer *Marc I Perceptron*: Multi-Layer Perceptron

**Idee:** Sehr viele Berechnungseinheiten, die erst durch ihre Interaktion „intelligent“ werden

- Seitdem ein stetes Auf und Ab: Hypes und Ernüchterungen
- Boom seit ca. 10 Jahren durch den enormen Anstieg an Rechenkapazität

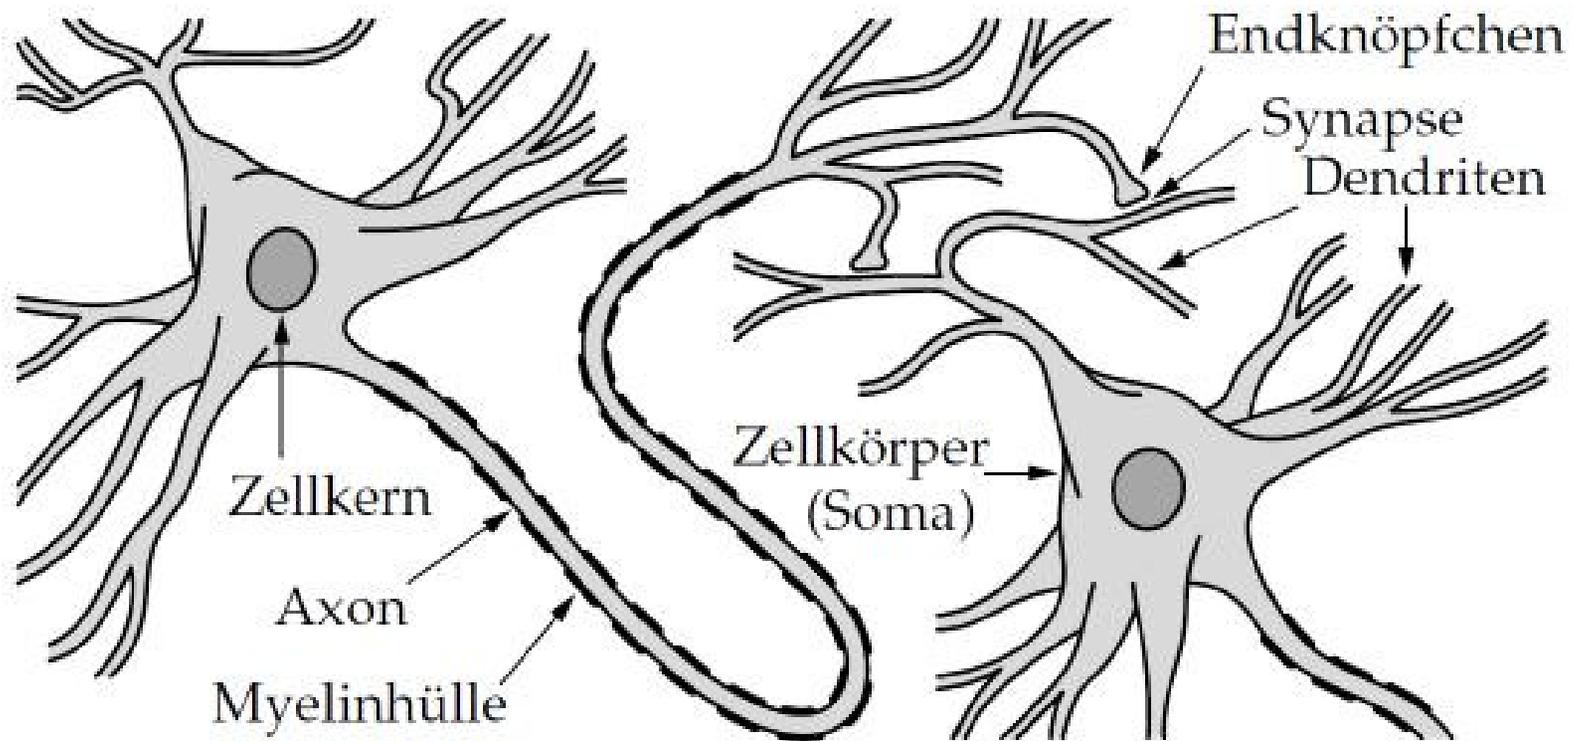


Warren McCulloch and Walter Pitts



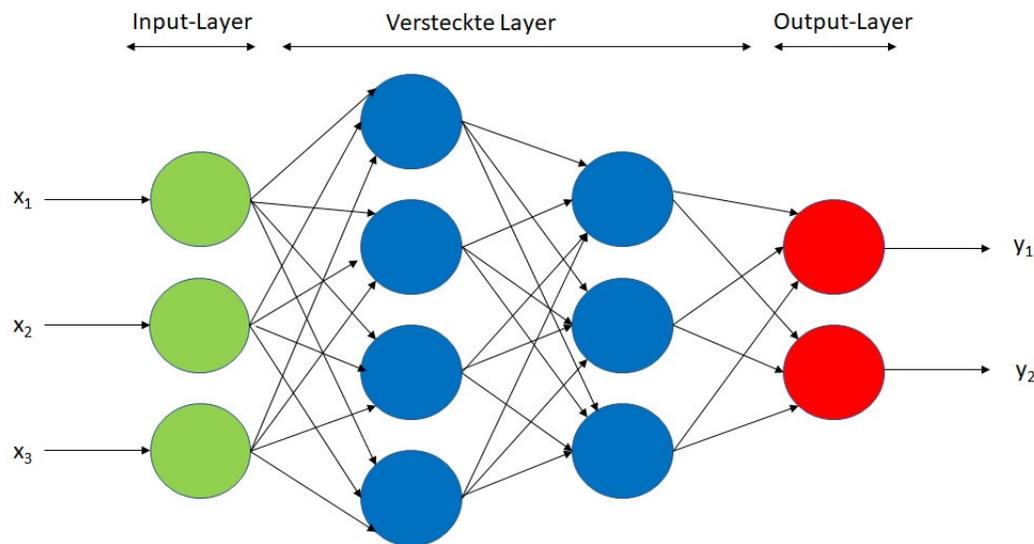
Frank Rosenblatt

# Neuronale Netze: Motivation aus der Gehirnforschung



Bildquelle: Wikipedia

# Input – Versteckte Schichten - Output



## Komponenten:

- Input Layer & Input Werte  $x_i$
- Versteckte Layer  $a$
- Output Layer & Output Werte  $y_i$
- Aktivierungsfunktion  $\varphi$
- Gewichte  $w_{ij}$

## Typische Aktivierungsfunktionen:

- Tangens Hyperbolicus
- Logistische Funktion  
 $f(x, \theta) = 1 / (1 + e^{-(x - \theta)})$
- Rectified Linear Unit (ReLU)  
 $f(x, \theta) = \max[0, x - \theta]$
- Leaky ReLU  
 $f(x, \theta) = \max(a(x - \theta), x - \theta)$

# Training des Netzes

- **Ausgangsfrage:**

- Gegeben sei eine Datenmenge bestehend aus Paaren (Input, Zielwert). Welche Stellschrauben gibt es um das Netz so zu optimieren, dass die Zielwerte bestmöglich reproduziert werden?

- **Antwort:**

- Passe die Gewichte so an, dass sich der Output mit jedem neuen Paar ein Stück weiter in Richtung der Zielwerte bewegt.

- **Mathematische Grundidee:**

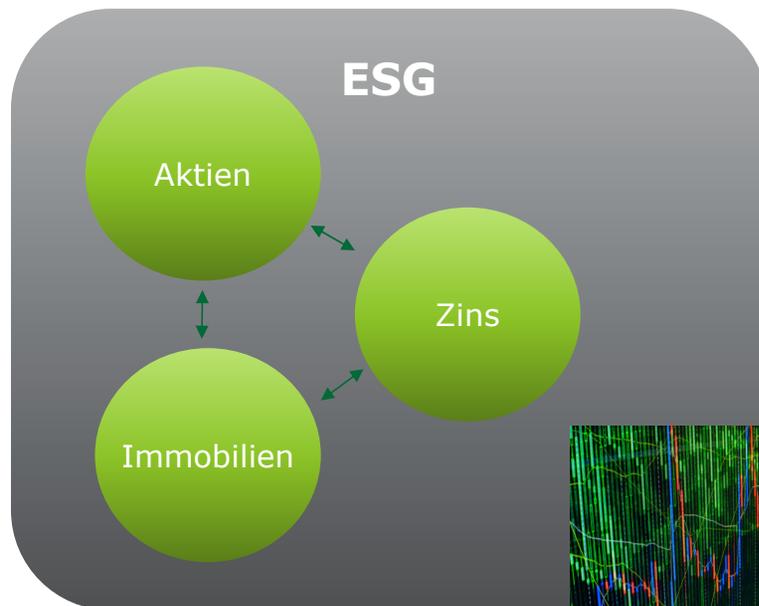
- Verwende das Gradientenabstiegsverfahren, um die Abhängigkeit des Fehlers von den Gewichten zu verringern

$$w_{ij}^{neu} = w_{ij}^{alt} - \eta \frac{\partial Err}{\partial w_{ij}}$$

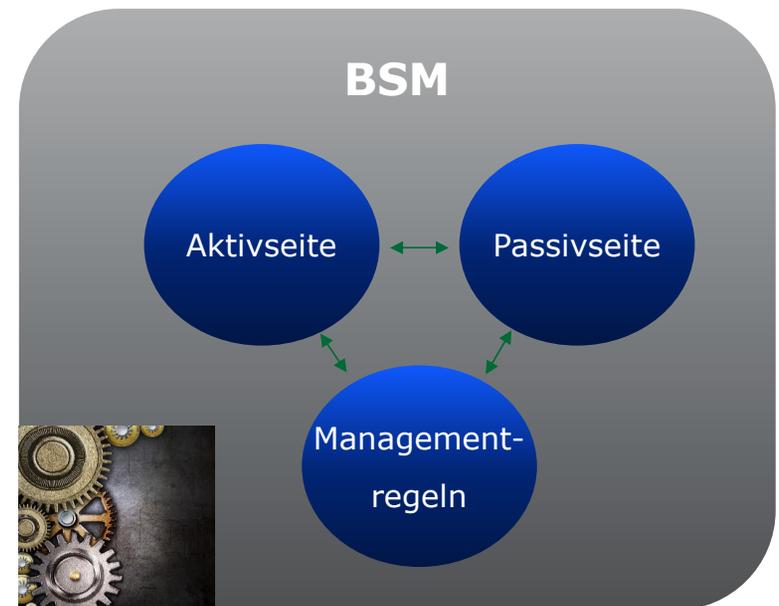
# **Umsetzung für das Branchensimulationsmodell**

## Illustration anhand eines Beispiels

# Automatisierung des BSM

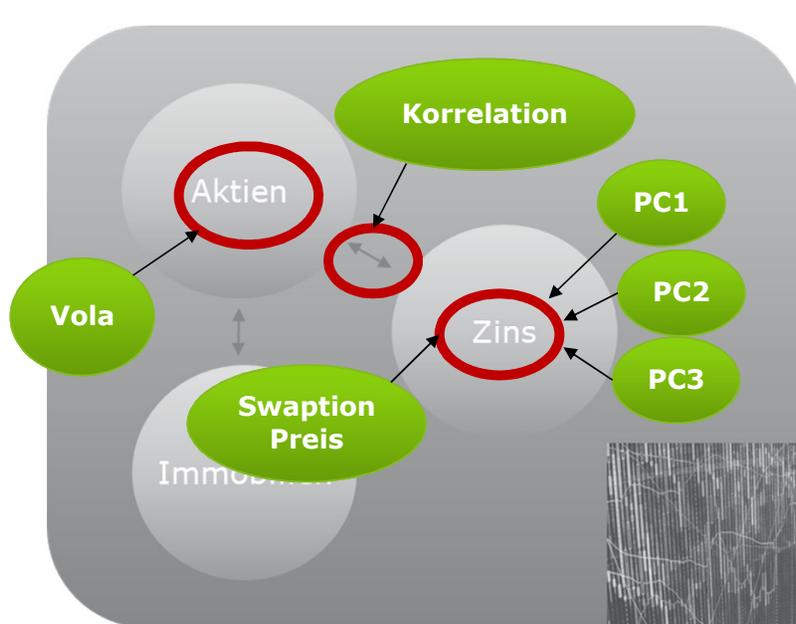


- Konstruktion der Zinskurve aus Hauptkomponenten
- Extrapolation nach Smith-Wilson
- Kalibrierung der Modelle
- Szenarien-Generierung unter Korrelationen



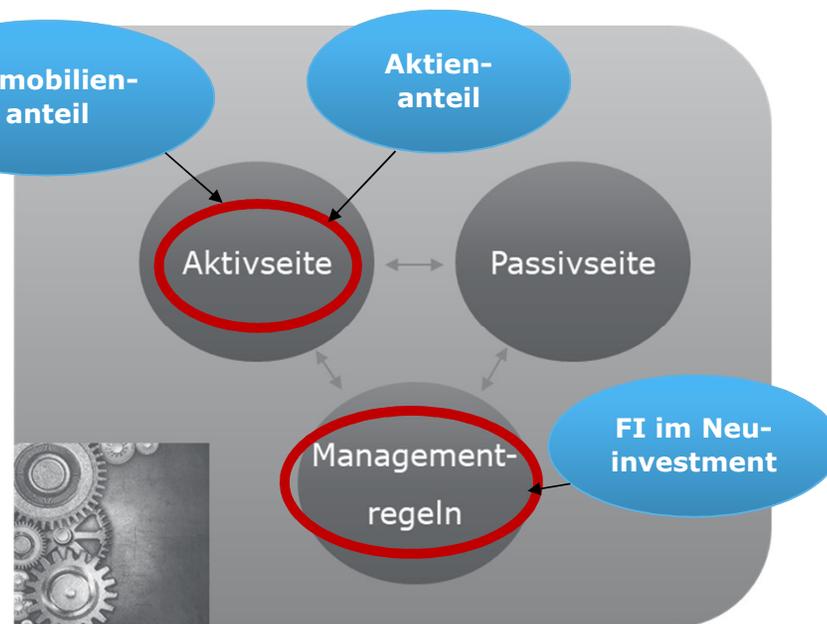
- Aufteilung der Aktiva zum Stichtag
- Anpassung zeitabhängige und zeitunabhängige Managementregeln
- Automatisierte und vollständig parallelisierte Läufe

# Beispiel mit 9 Sensitivitäts-Dimensionen



## Parametrisierung

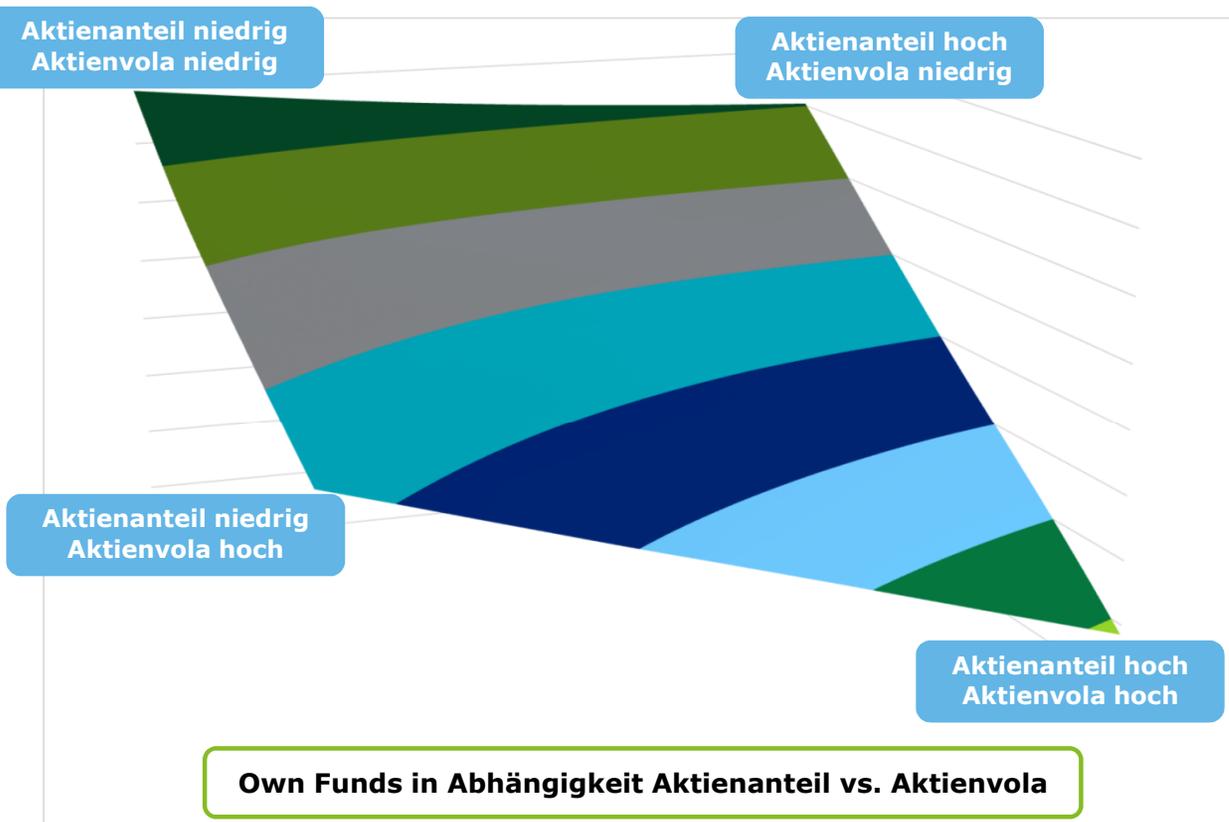
- der Zinskurve über drei Hauptkomponenten
- der Aktienvola als Kalibrierungsziel
- der Swaptionvola für Zinskalibrierung
- der Korrelation von Short Rate und Aktien



## Parametrisierung

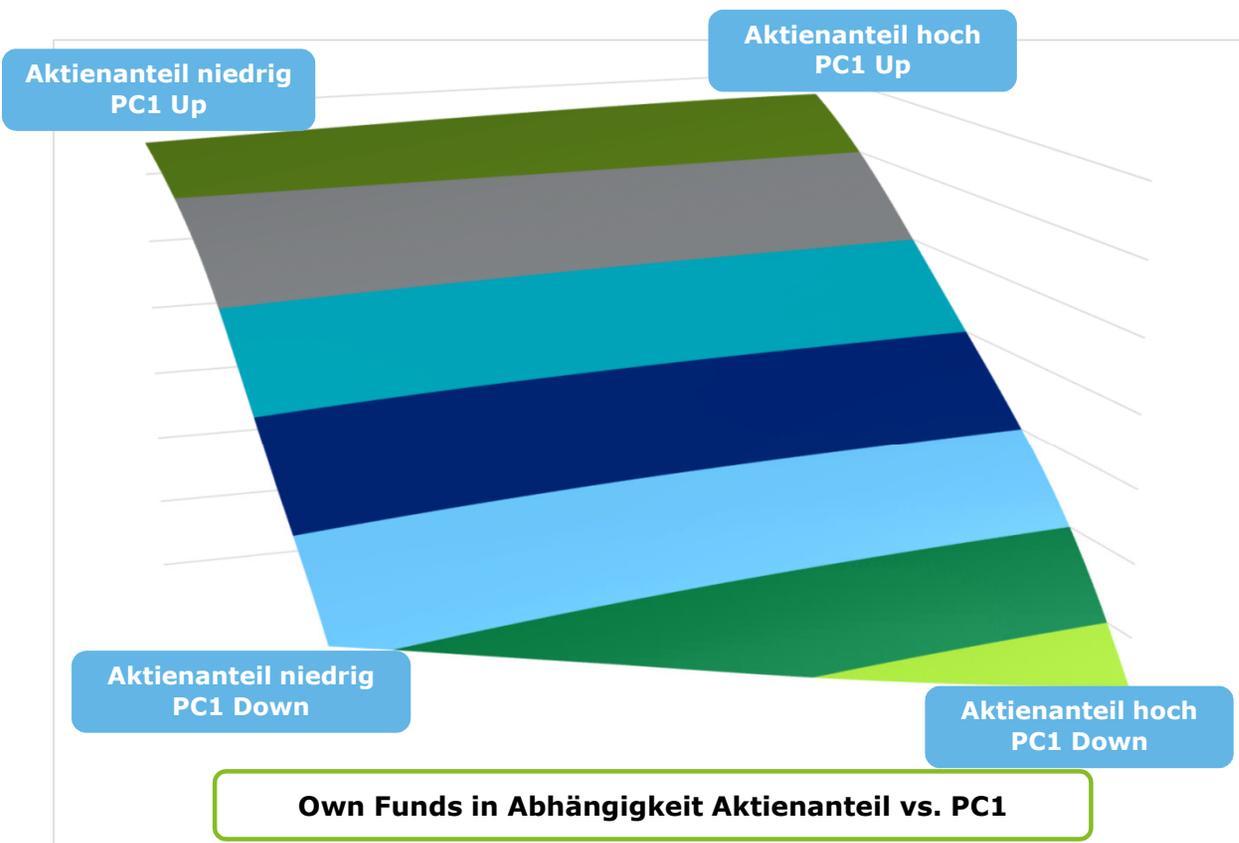
- des Anteils von Aktien im Startportfolio
- des Anteils von Immobilien im Startportfolio
- des Mindest- und Zielanteils Fixed Income

# Exemplarische Analyse BSM: Aktien



- Modelliert wird Umschichtung zwischen **Aktien** und **Fixed Income** („risikofrei“) zum Berechnungstichtag
- **Asymmetrie des Geschäftsmodells** bewirkt negativen Einfluss von erhöhter Aktienvolatilität
- Dieser Effekt steigt mit zunehmendem **Aktienanteil**
- Für hypothetische Aktienvolatilität von Null existieren nur noch bilanzielle und **Durations-Effekte**

# Exemplarische Analyse BSM: Aktien



- PC1 bewirkt im Wesentlichen **Parallelverschiebung** der **Zinskurve**
- **Duration Passiva** größer als Duration Aktiva
- Hoher Aktienanteil bewirkt weitere **Verkürzung** der aktivseitigen **Duration**
- In **Niedrigzins-Szenarien** schadet dies zusätzlich den Ergebnissen
- In **Hochzins-Szenarien** wird negativer Effekt durch erhöhte Volatilität durch positiven Effekt aus Durationsverkürzung überkompensiert

# Fallstudie BSM: Vergleich Regressionsmethoden

	Mean Absolute Error
Informationskriterium AIC	0,13 %
Random Forest (XGB)	0,18 %
Künstliches Neuronales Netz	0,13 %
Validierungspunkte (1k Sim)	0,07 %

50k Trainingsdaten mit je 2 inneren Simulationen, Fehler in % des Marktwerts der Aktiva zu t=0

- Auswertung auf 80 zufällig im Fittingraum verteilten Out-Of-Sample-Validierungspunkten
- AIC und künstliche neuronale Netze mit höchster Güte
- Ungenauigkeit der Predictions fast im Bereich des Fehlers der Validierungspunkte
- Weiteres Optimierungspotential bei Entscheidungsbäumen

Welcher der Algorithmen die besten Ergebnisse liefert hängt sehr stark vom individuellen Problem ab.  
**→ Der optimale Weg ist jeweils ein Vergleich aller Varianten.**

# Kontakt



**Prof. Dr. Christian Weiß**

Externer Berater

Aktuar DAV

B&W Deloitte GmbH

Magnusstraße 11

50672 Köln

**Tel. +49 (0)151 11 66 52 66**

**E-Mail: chrweiss@deloitte.de**



**Johannes Fabrega y Escatllar**

Manager

Aktuar DAV

B&W Deloitte GmbH

Magnusstraße 11

50672 Köln

**Tel. +49 (0)221 97324 520**

**E-Mail: jfabrega@deloitte.de**