



UNIVERSITÄT
DES
SAARLANDES



SIC Saarland Informatics
Campus

Transparenz und Erklärbarkeit algorithmischer Entscheidungssysteme

Begründung, Sorten, Herausforderungen

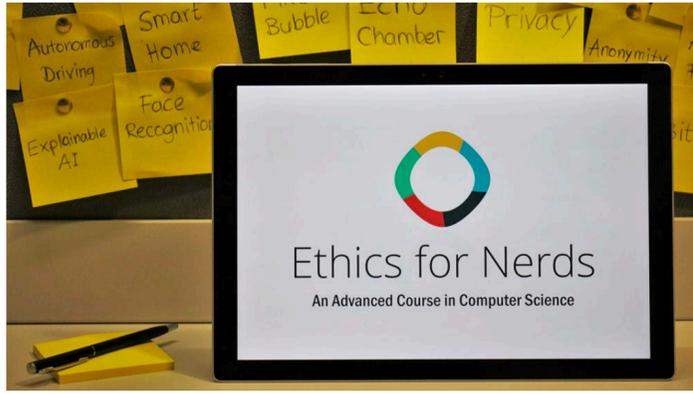


**Explainable
Intelligent
Systems**

37. Konferenz der
Informationsfreiheitsbeauftragten (IFK)

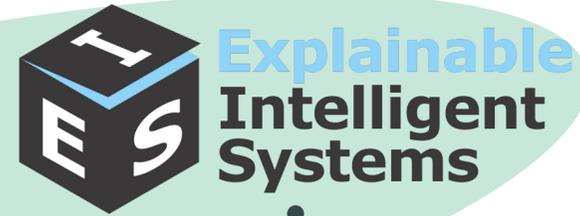
12. Juni 2019





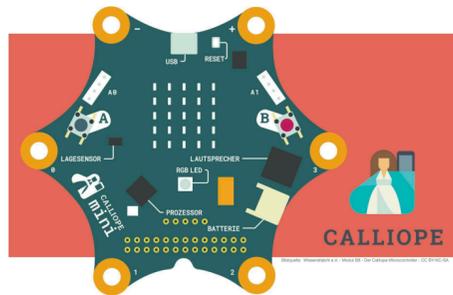
Als Dozent: *Ethics for Nerds*
(Vertiefungsvorlesung)
seit 2016

Forschung und
Dissertationsprojekt (seit 2018)
zu Maschinenerklärbarkeit



Bachelor (2011) und Master
(2013) in Informatik an der Uds

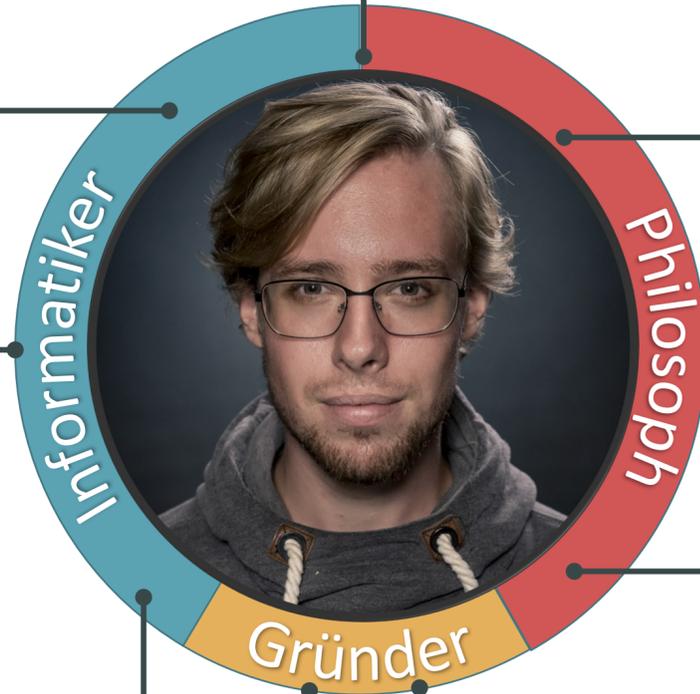
Seit 2015 Wissenschaftlicher
Mitarbeiter an der Dependable
Systems Group von
Professor Holger Hermanns



Projekt mit Professorin Verena Wolf zur
Erforschung didaktischer Konzepte für
Digitale Bildung im Grundschulalter inkl.
Calliope



Kevin Baum



Master (2014) in
Philosophie an der Uds



Seit 2015
Wissenschaftlicher
Mitarbeiter am
Lehrstuhl für
Praktische
Philosophie von
Professorin Ulla
Wessels und
Professor Christoph
Fehige



EXIST-Gründerstipendium
(2016 – 2017)



Mitgründer des
saarländischen
Think Tank für
gute Digitalisierung



Als Dozent: Seminare
zu Normativer Ethik,
Angewandte Ethik,
vor allem
Computerethik

Forschung und
Dissertationsprojekt
zur Ethik kollektiven
Handelns

Digitale Verwaltung

Das Amt und meine Daten

Dank Digitalisierung soll die Verwaltung in Österreich bequemer und effizienter werden. Doch schon jetzt zeigt sich: Mit dieser technischen Revolution in den Amtsstuben tauchen auch neue Probleme auf.

Von Anja Reiter, 11. Mai 2019, 10:44 Uhr / ZEIT Österreich Nr. 20/2019, 9. Mai 2019 / 77 Kommentare

<https://www.zeit.de/2019/20/digitale-verwaltung-behoerden-aemter-effizienzsteigerung-probleme>

Big Data bei der Polizei: Hessen sucht mit Palantir-Software nach Gefährdern

Hessen läutet eine grundlegende Veränderung der Polizeiarbeit in Deutschland ein: Eine Software von Palantir verknüpft Datenbestände neu, wertet sie aus und soll etwa sogenannte Gefährder identifizieren. Dies ist nicht nur rechtlich fragwürdig, sondern dürfte weitreichende Folgen haben, schreibt der Kriminologe Tobias Singelnstein im Grundrechte-Report 2019.

03.06.2019 um 12:00 Uhr - Gastbeitrag, Tobias Singelnstein - eine Ergänzung

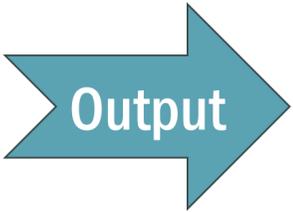
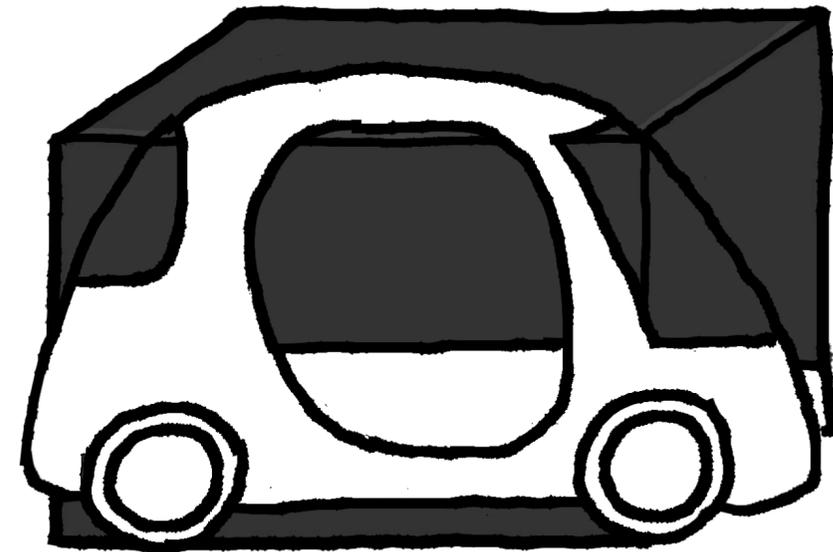
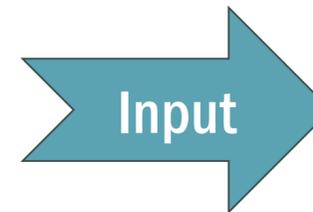
<https://netzpolitik.org/2019/big-data-bei-der-polizei-hessen-sucht-mit-palantir-software-nach-gefaehrdern/>

Algorithmus/Computerprogramm

```
WHILE A <> B DO
BEGIN
  IF B > A THEN
  BEGIN
    H := A; A := B; B := H (* A und B vertauschen *)
  END;
  A := A - B (* Schritt2: (* A durch A-B ersetzen *) *)
END;
(* Schritt3: *)
(* Solange A ungleich B *)
(* Falls B größer als A *)
```

Spezielle Sorte von *Künstlicher Intelligenz* (KI): *Lernende Software/Machine Learning* (ML)

VS.

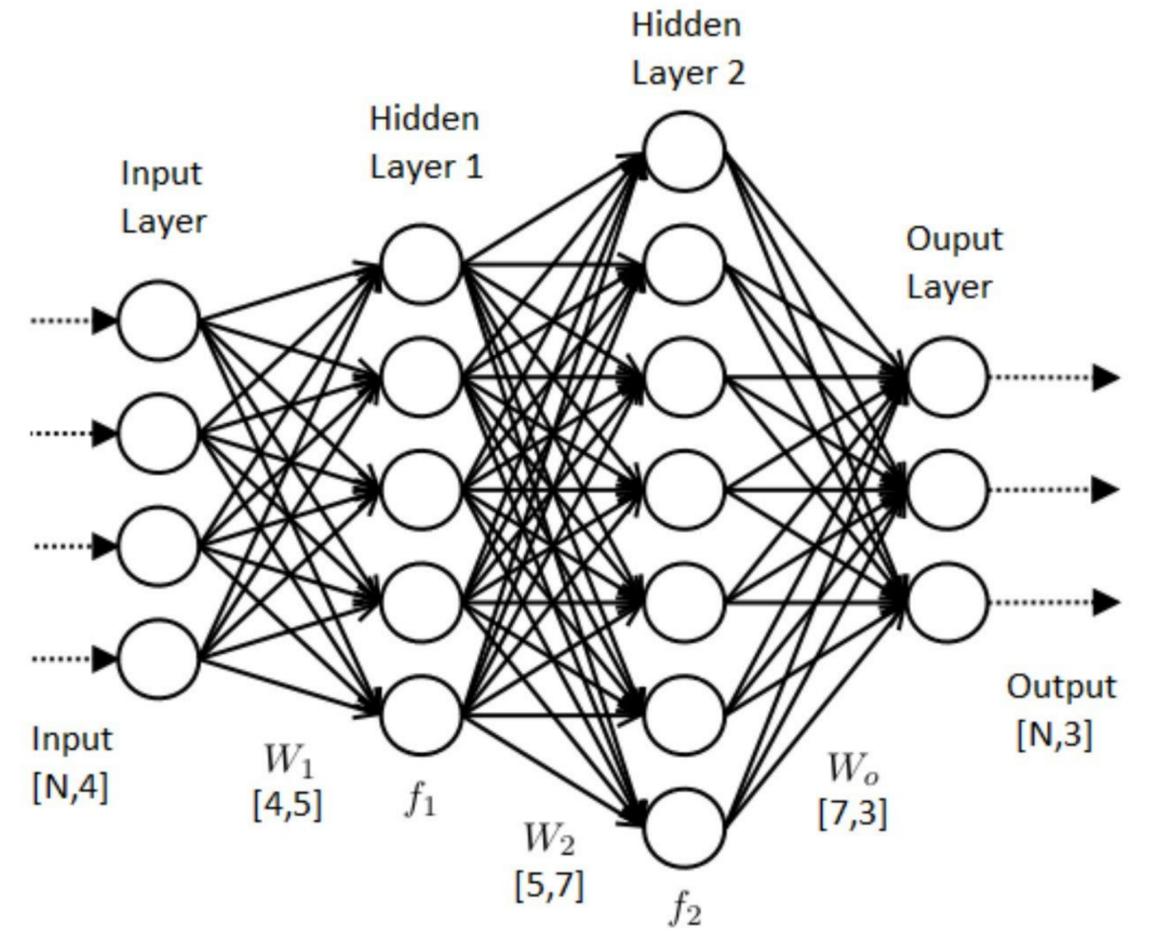
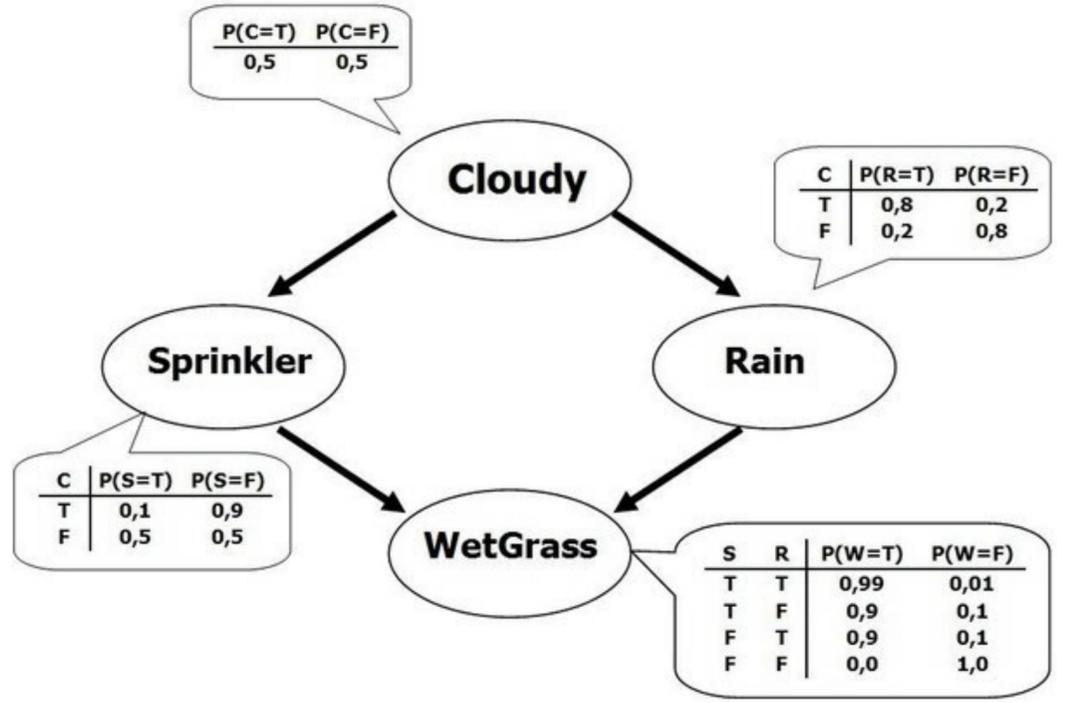
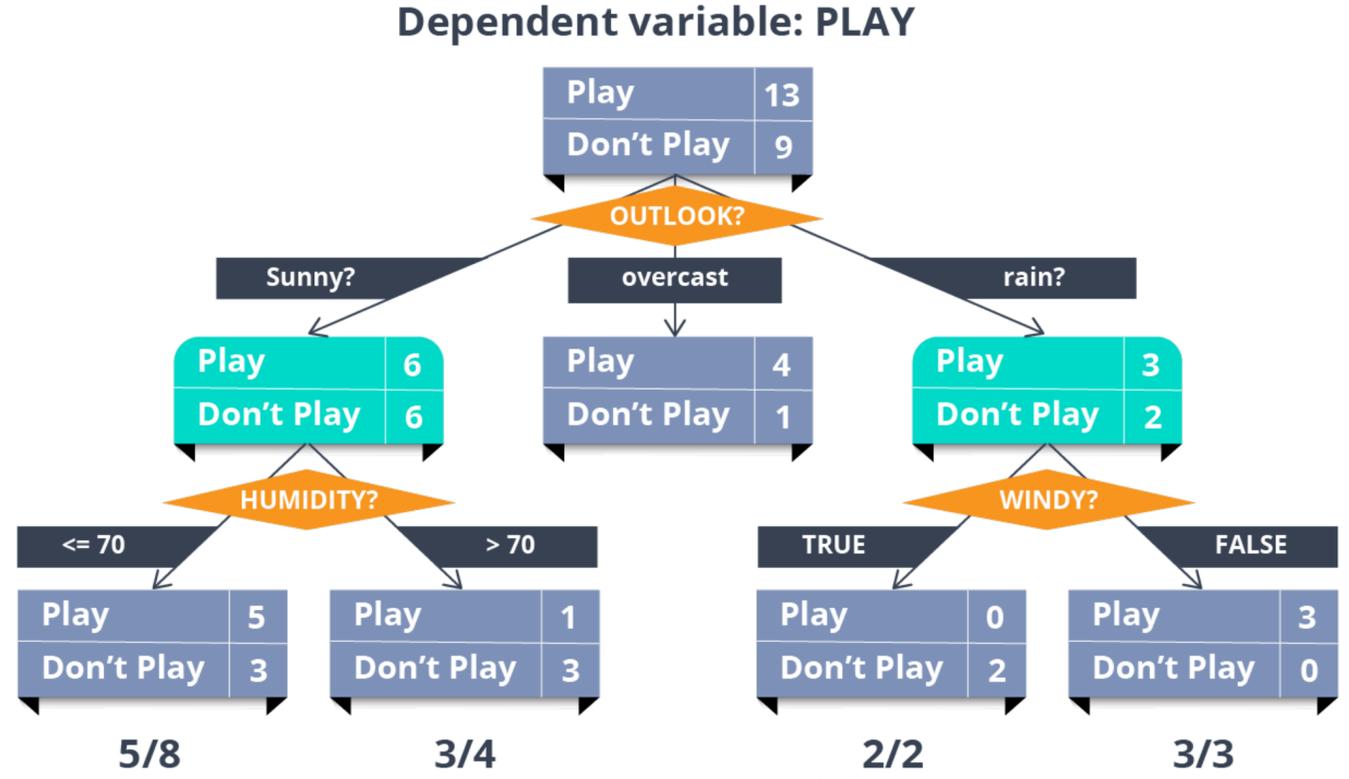


1. System \neq Software \neq Algorithmen \neq KI \neq Machine Learning
2. Das Stück Software nennt man gemeinhin „Modell“
3. Unterschiedliche Gründe für Modelle als Black Box:
praktische & theoretische

```

53
54 uppercase_sample = 'ABCDEFGHIJKLMNOPQRSTUVWXYZ'
55 lowercase_sample = 'abcdefghijklmnopqrstuvwxyz'
56 digit_sample = '0123456789'
57 if keras.backend.image_dim_ordering() != 'tf' and count <= 100:
58     keras.backend.set_image_dim_ordering('tf')
59     print("INFO: '~/keras/keras.json' sets 'image_dim_ordering' to "
60         "'th', temporarily setting to 'tf'")
61
62 # Create TF session and set as Keras backend session
63 sess = tf.Session()
64 keras.backend.set_session(sess)
65
66 # Get MNIST test data
67 X_train, Y_train, X_test, Y_test = data_mnist(train_start=train_start,
68     train_end=train_end,
69     test_start=test_start,
70     test_end=test_end)
71
72 assert Y_train.shape[1] == 10

```



„Daten sind das neue Öl“ – ML der neue Motor?

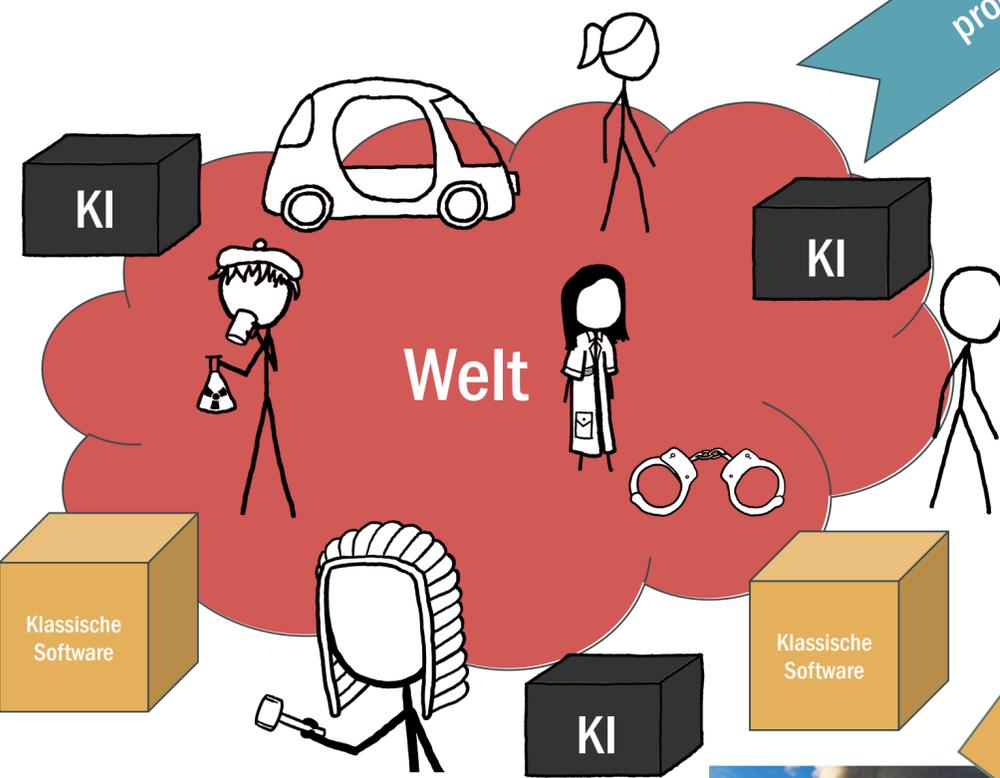


Immense Datenmengen (aka „Big Data“)

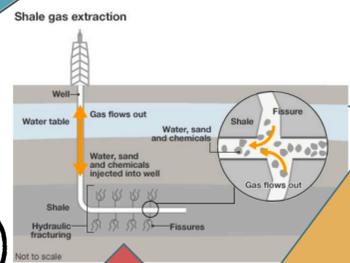


sind Basis für

Lernalgorithmen



produziert



Resultiert in



beeinflusst/ist wirksamer Teil von

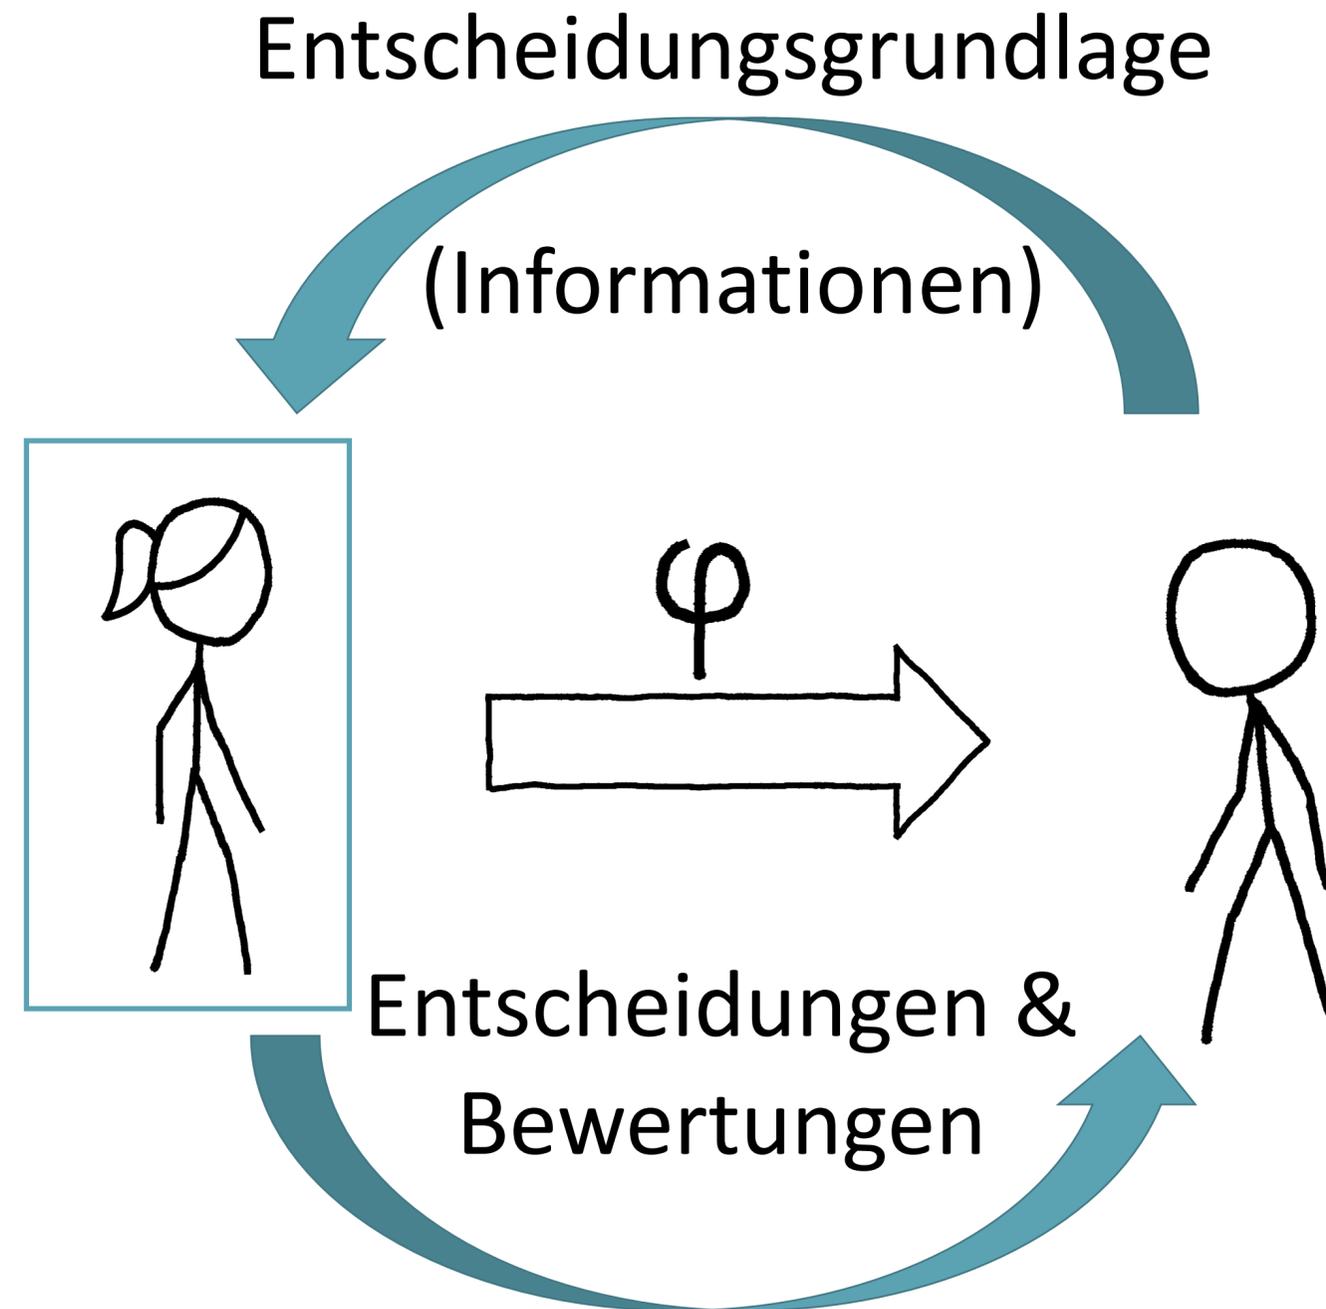
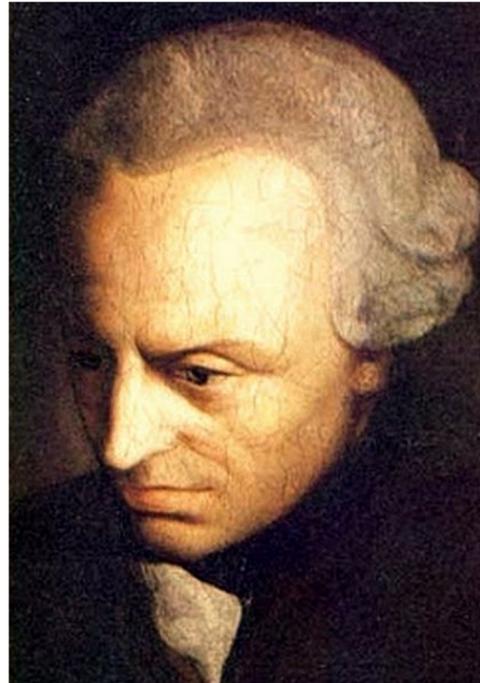
KI-System



Subjekt und Objekt: Klassisch

Bislang:

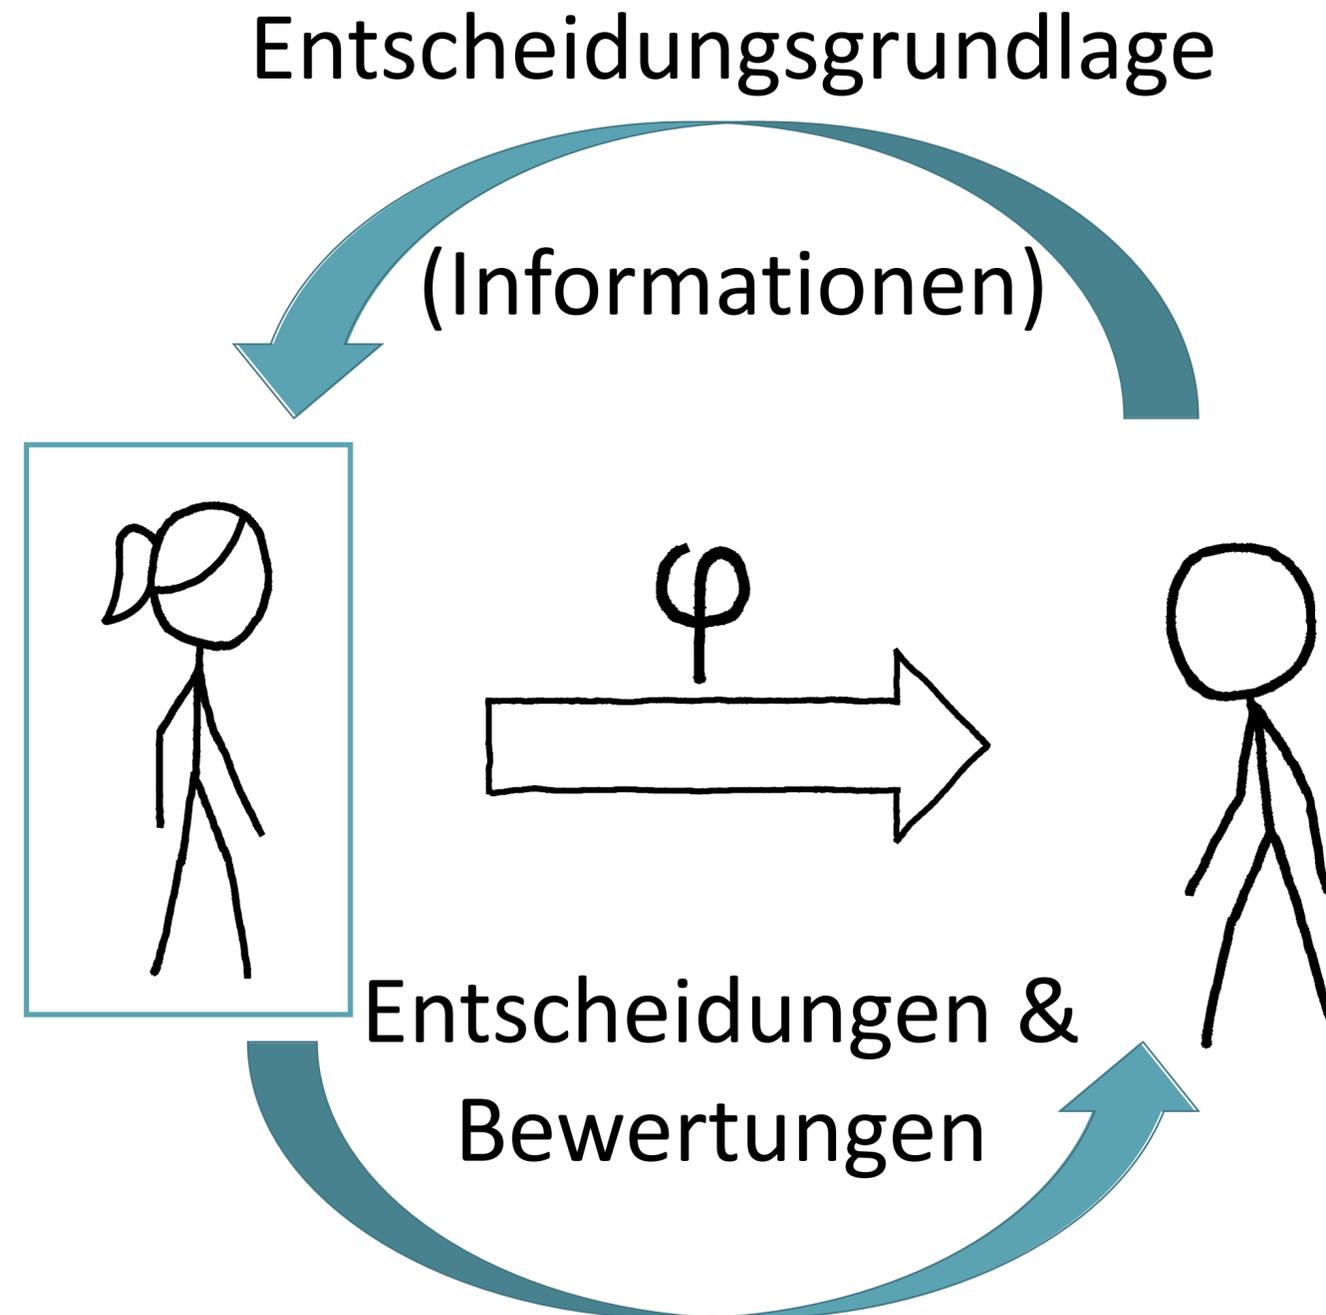
- Menschen
 - erfahrungsbasiert vs. regelbasiert
 - alltäglich vs. institutionell



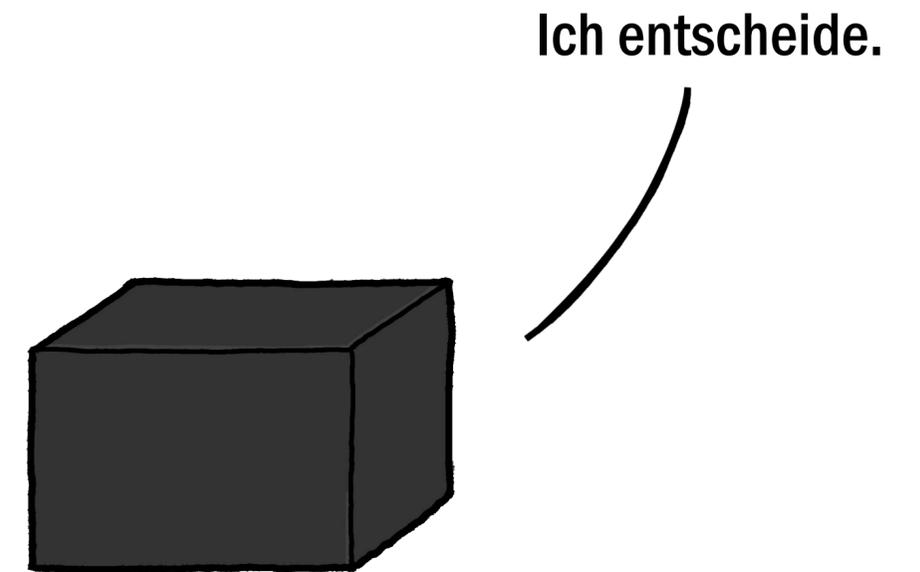
Subjekt und Objekt: Klassisch

Bislang:

- Menschen
 - erfahrungsbasiert vs. regelbasiert
 - alltäglich vs. institutionell



Ein (unvermeidlicher?) Trend?



Subjekt und Objekt

Bislang:

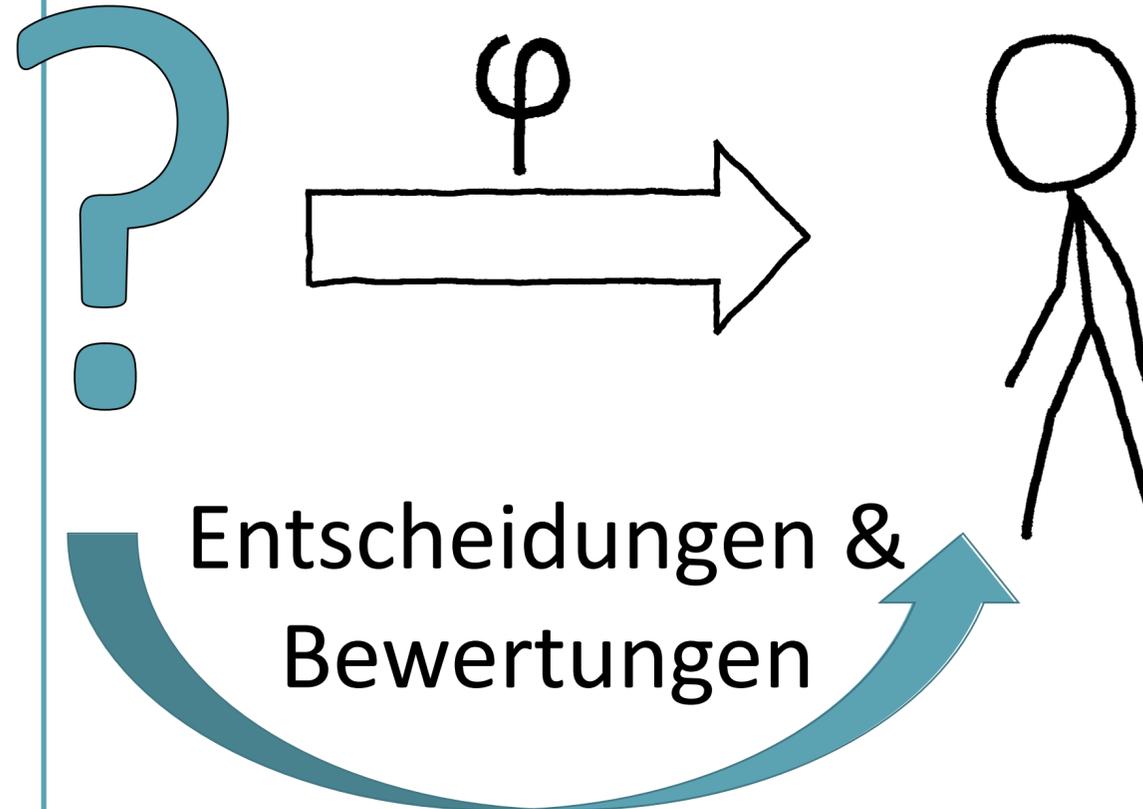
- Menschen
 - erfahrungsbasiert vs. regelbasiert
 - alltäglich vs. institutionell

Neuland:

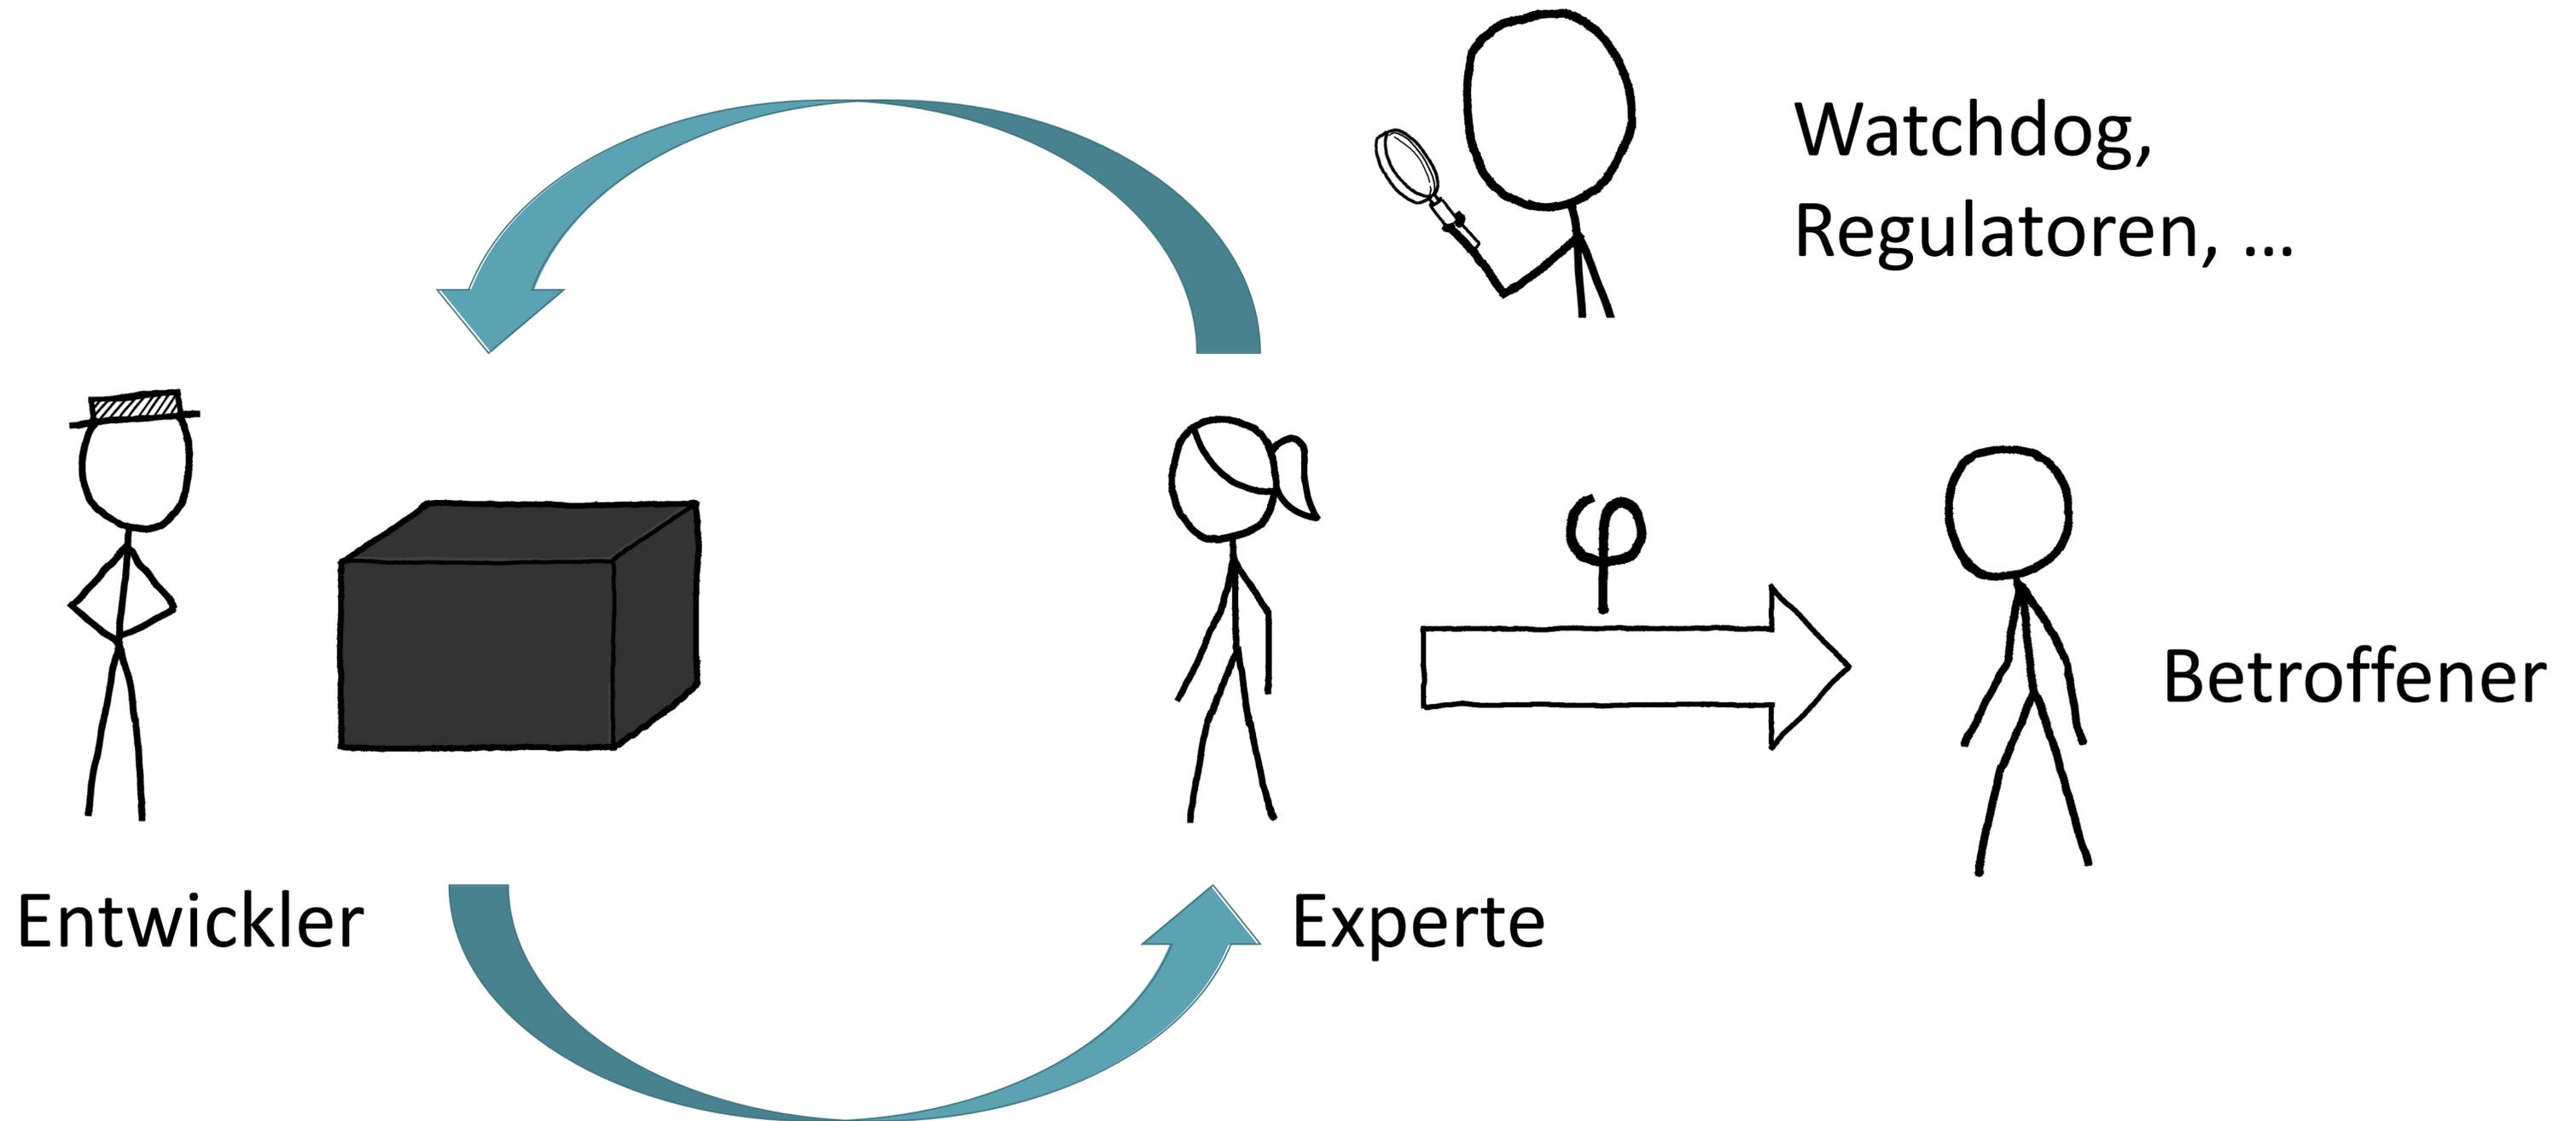
- Menschen, unterstützt von Algorithmen
- Algorithmen allein

Entscheidungsgrundlage

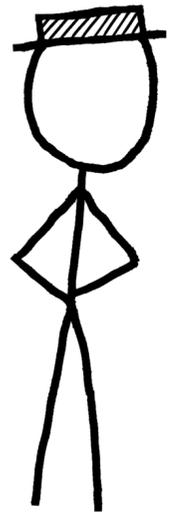
(Informationen)




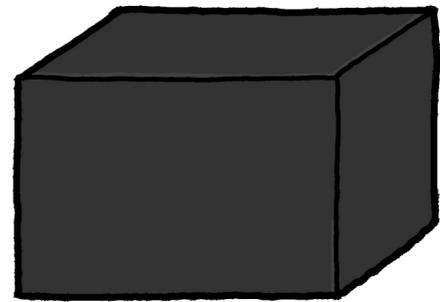
Perspektiven



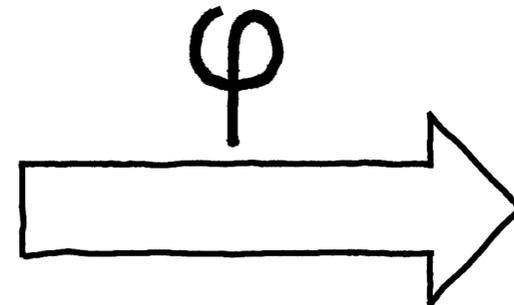
Perspektiven



Entwickler

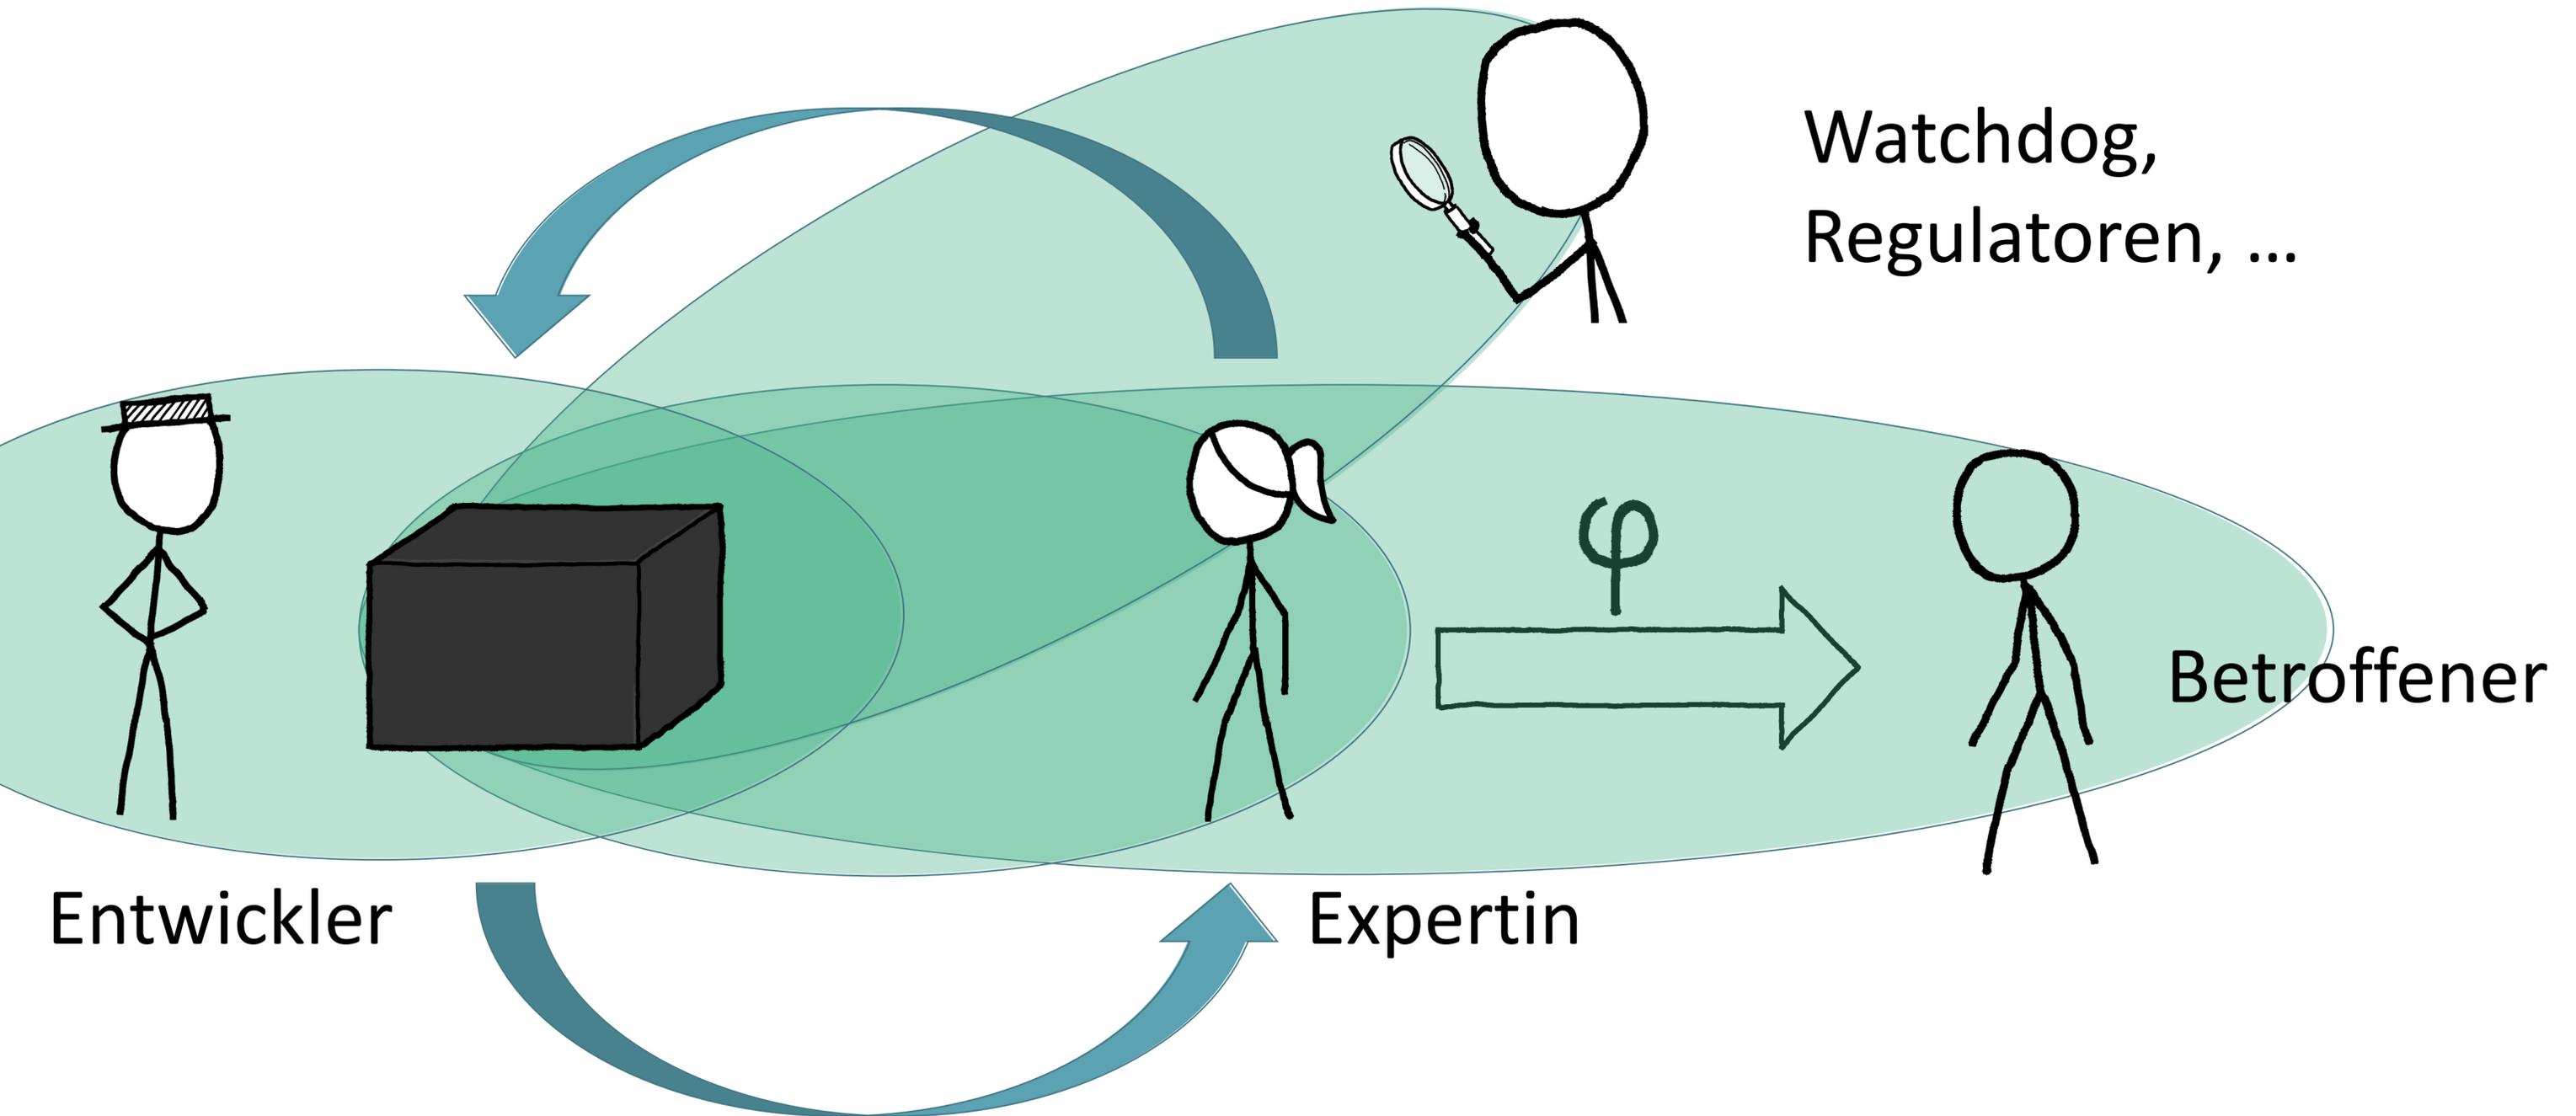


Watchdog,
Regulatoren, ...



Betroffener

Perspektiven



Typ 1: Right to be Informed

Suitable GDPR articles

Art. 12 GDPR Transparent information, communication and modalities for the exercise of the rights of the data subject, **Art. 13 GDPR** Information to be provided where personal data are collected from the data subject, **Art. 14 GDPR** Information to be provided where personal data have not been obtained from the data subject

<https://gdpr-info.eu/issues/right-to-be-informed/>

Nicht: Right to Explanation

- Nicht verwechseln mit dem *Right to Explanation*. Das ist nur Willensbekundung, Teil eines Erwägungsgrundes.
- Wir wüssten auch gar nicht, wie das gehen soll, zumindest nicht bei ‚modernen‘ Verfahren. (Später mehr dazu.)
- Zum Teil aber womöglich impliziertes Recht.

Right to Explanation: a Right that Never Was (in GDPR)

Posted on 1st March 2018 by Eve the Analyst

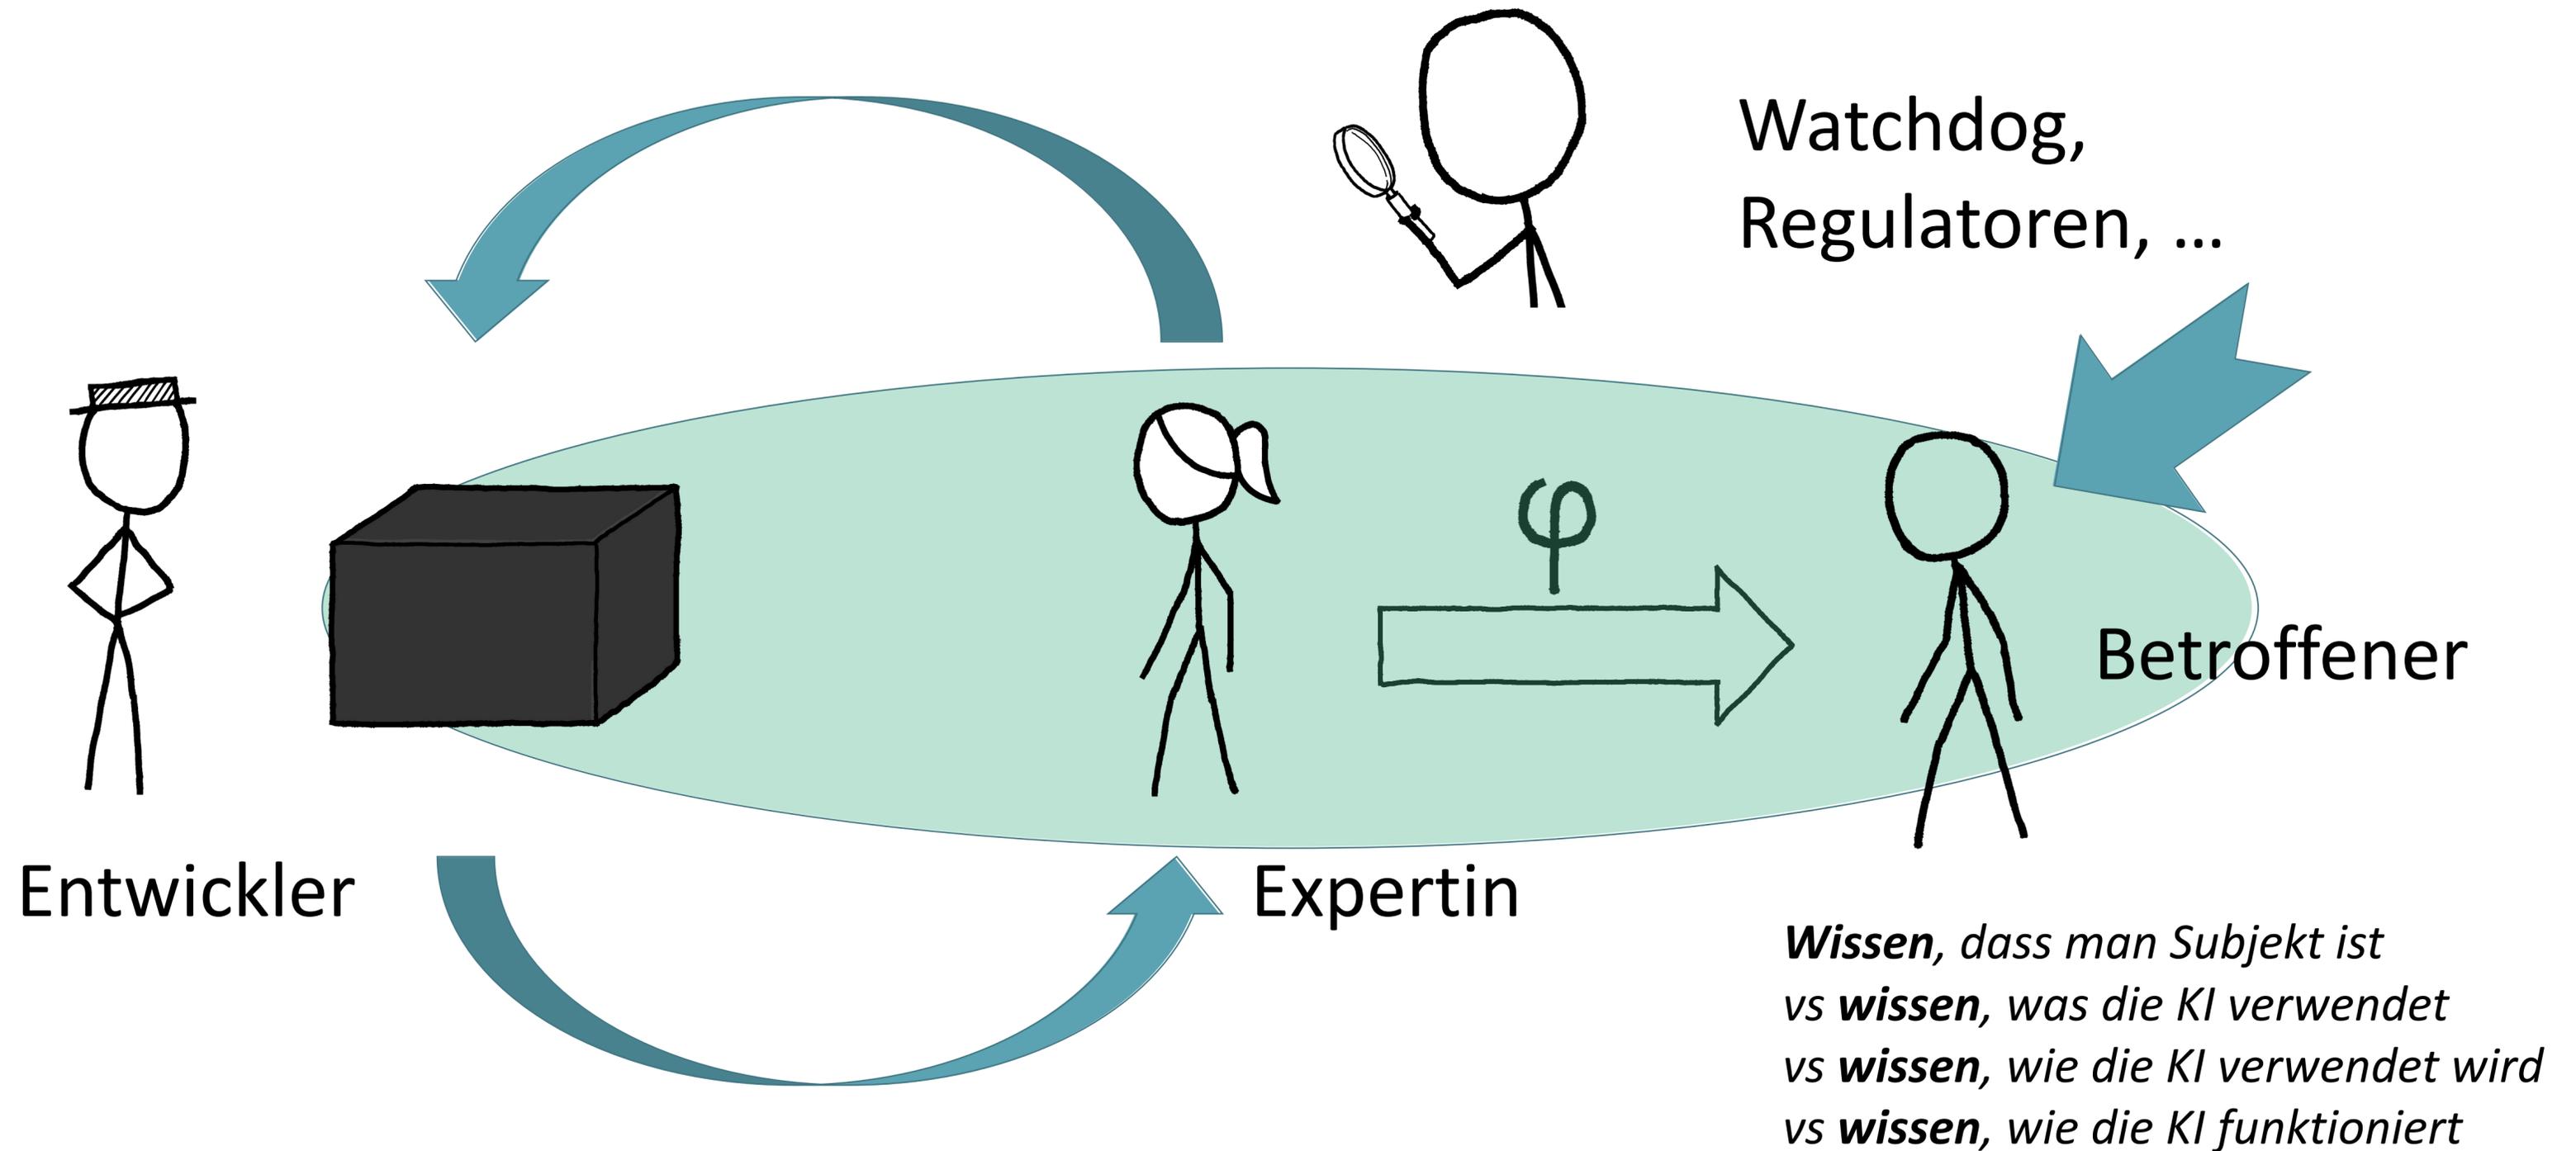
<http://datawanderings.com/2018/03/01/right-to-explanation/>

Recital 71 EU GDPR

*In any case, such processing should be subject to suitable safeguards, which should include **specific information to the data subject and the right to obtain human intervention, to express his or her point of view, to obtain an explanation of the decision reached after such assessment and to challenge the decision.***

<https://www.privacy-regulation.eu/en/r71.htm>

Typ-1-Transparenz: Relevante Perspektiven



Typ 1: Right to be Informed

Umsetzbarkeit? Höchstens eine regulatorische Herausforderung

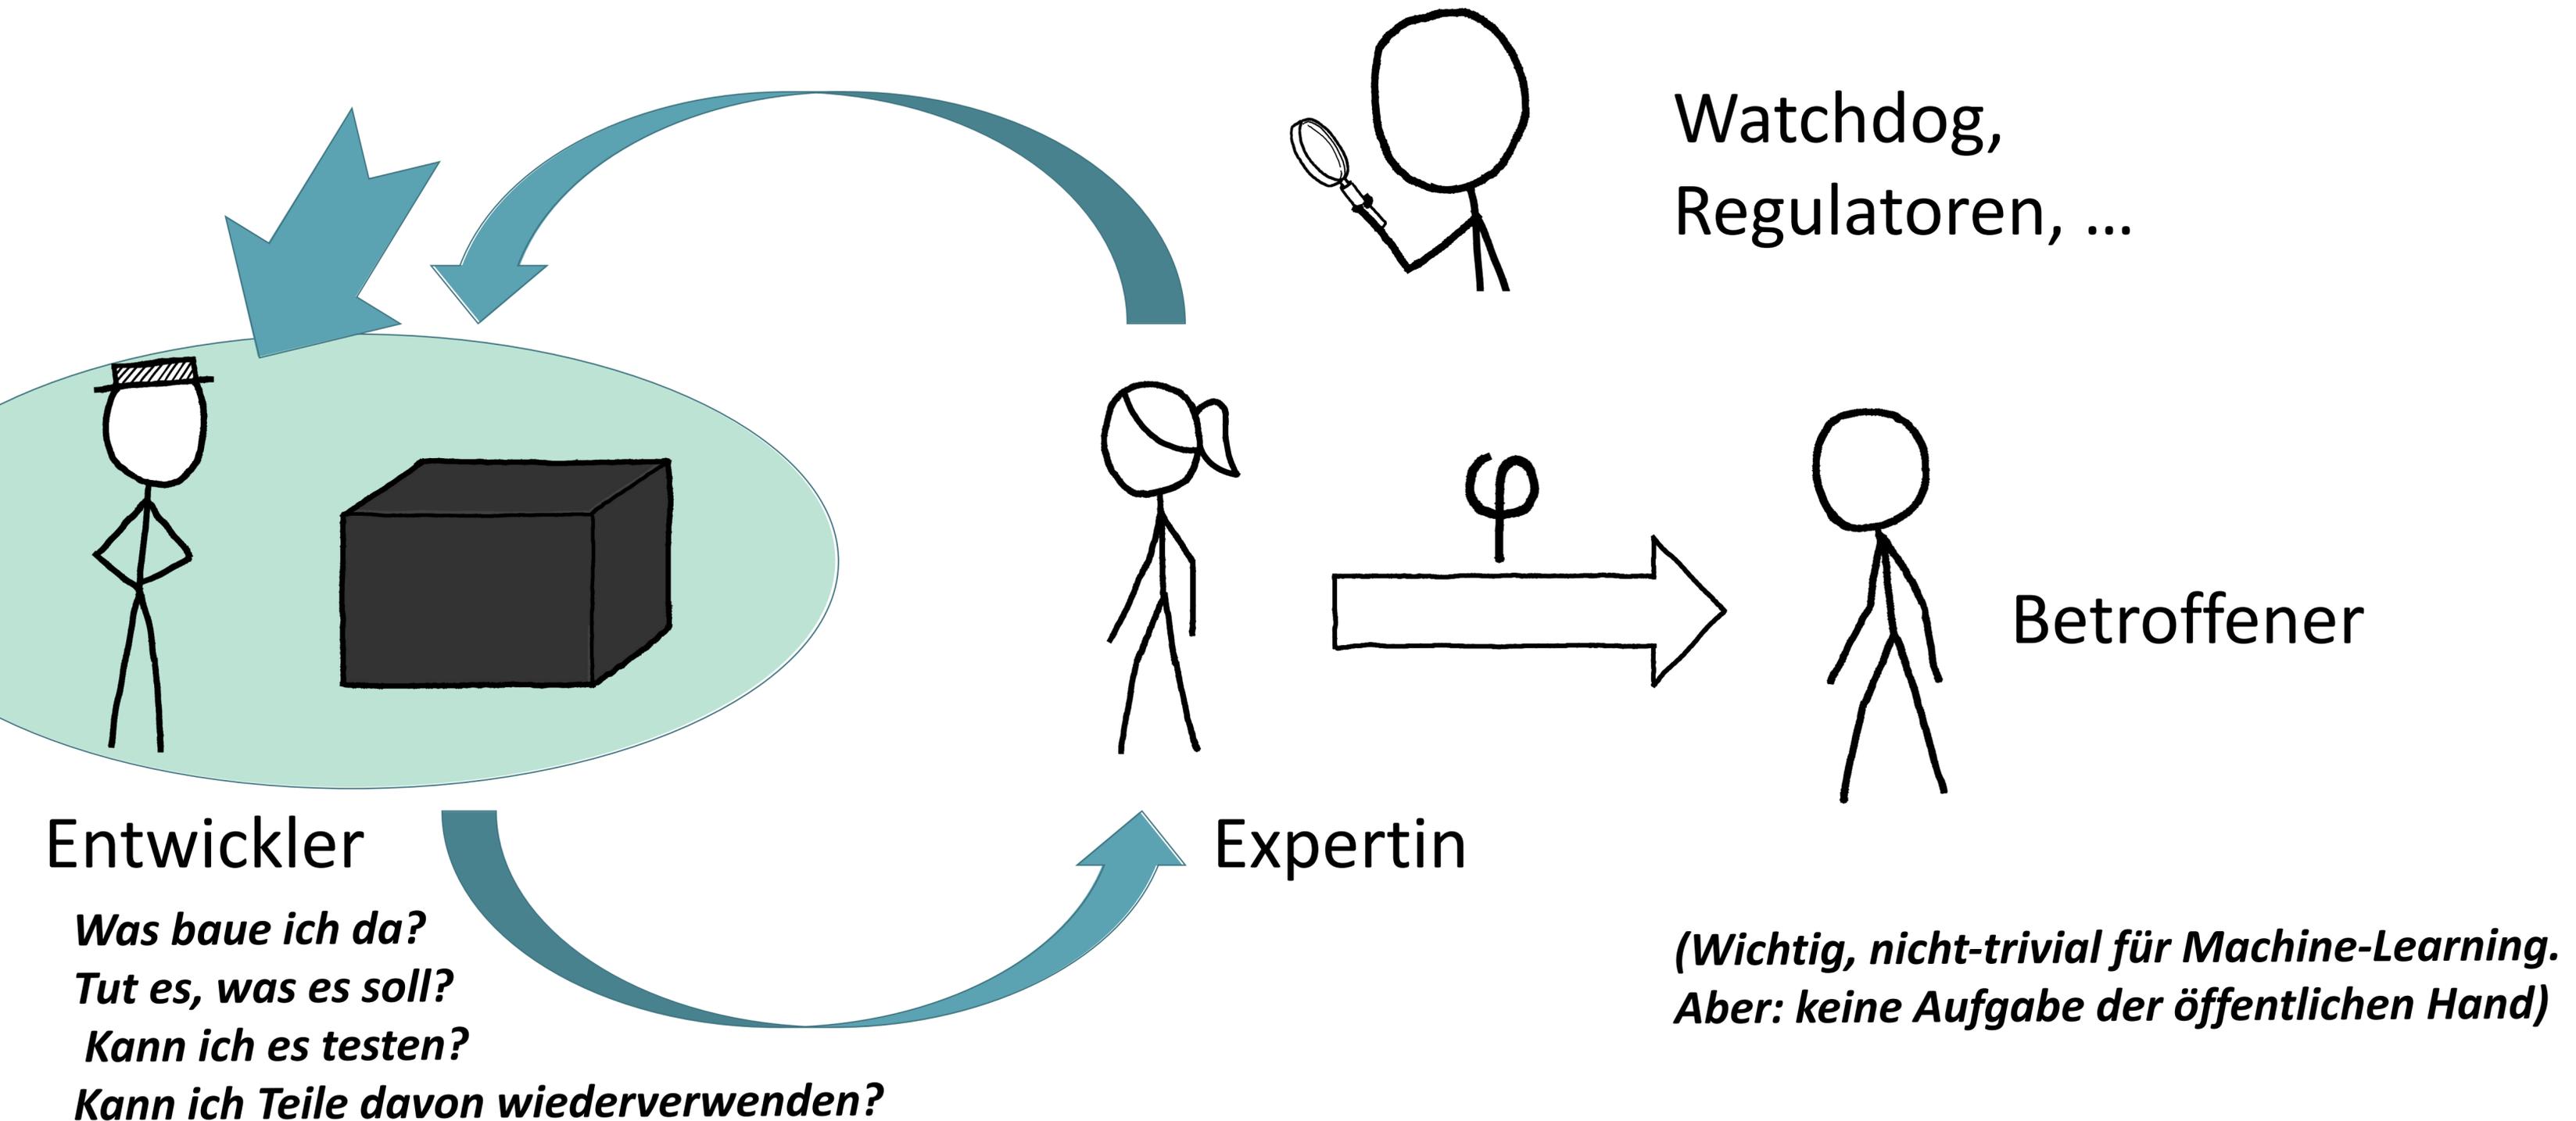
Warum wichtig? Ohne Kenntnis, kein Hinterfragen bzw. Einspruch

Typ 2:

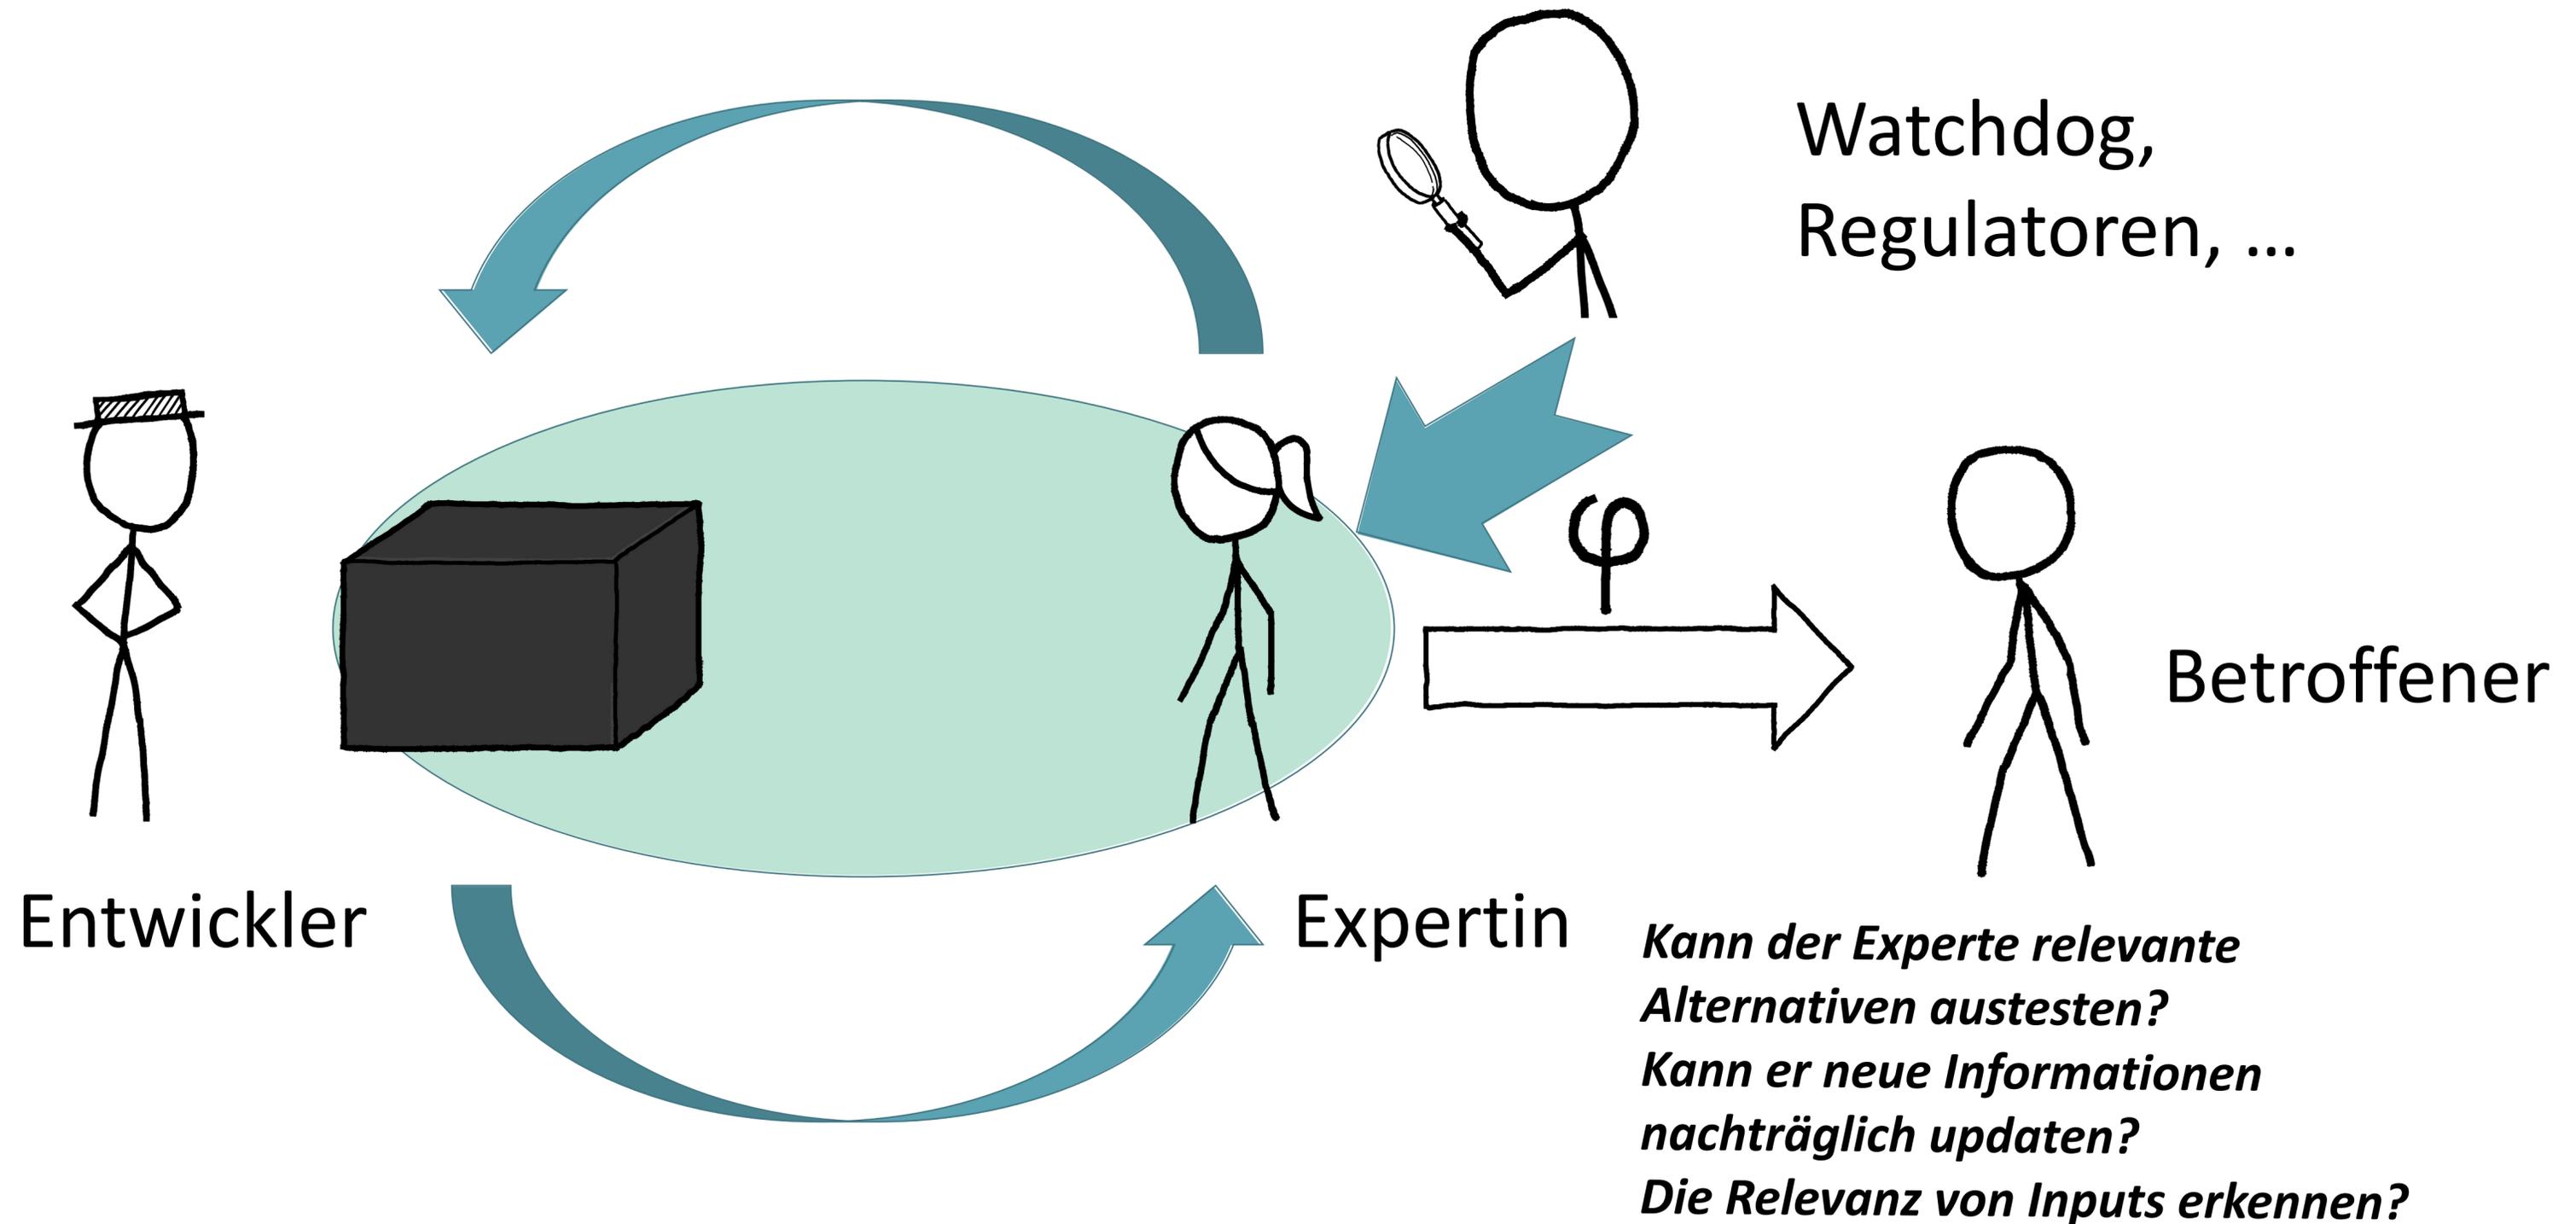
Transparenz durch
grundlegendes Verstehen,
Testbarmachung (Validierbarkeit) und
formale Explikation

(auf Ebene des Systems und auf Ebene seiner Entscheidungen)

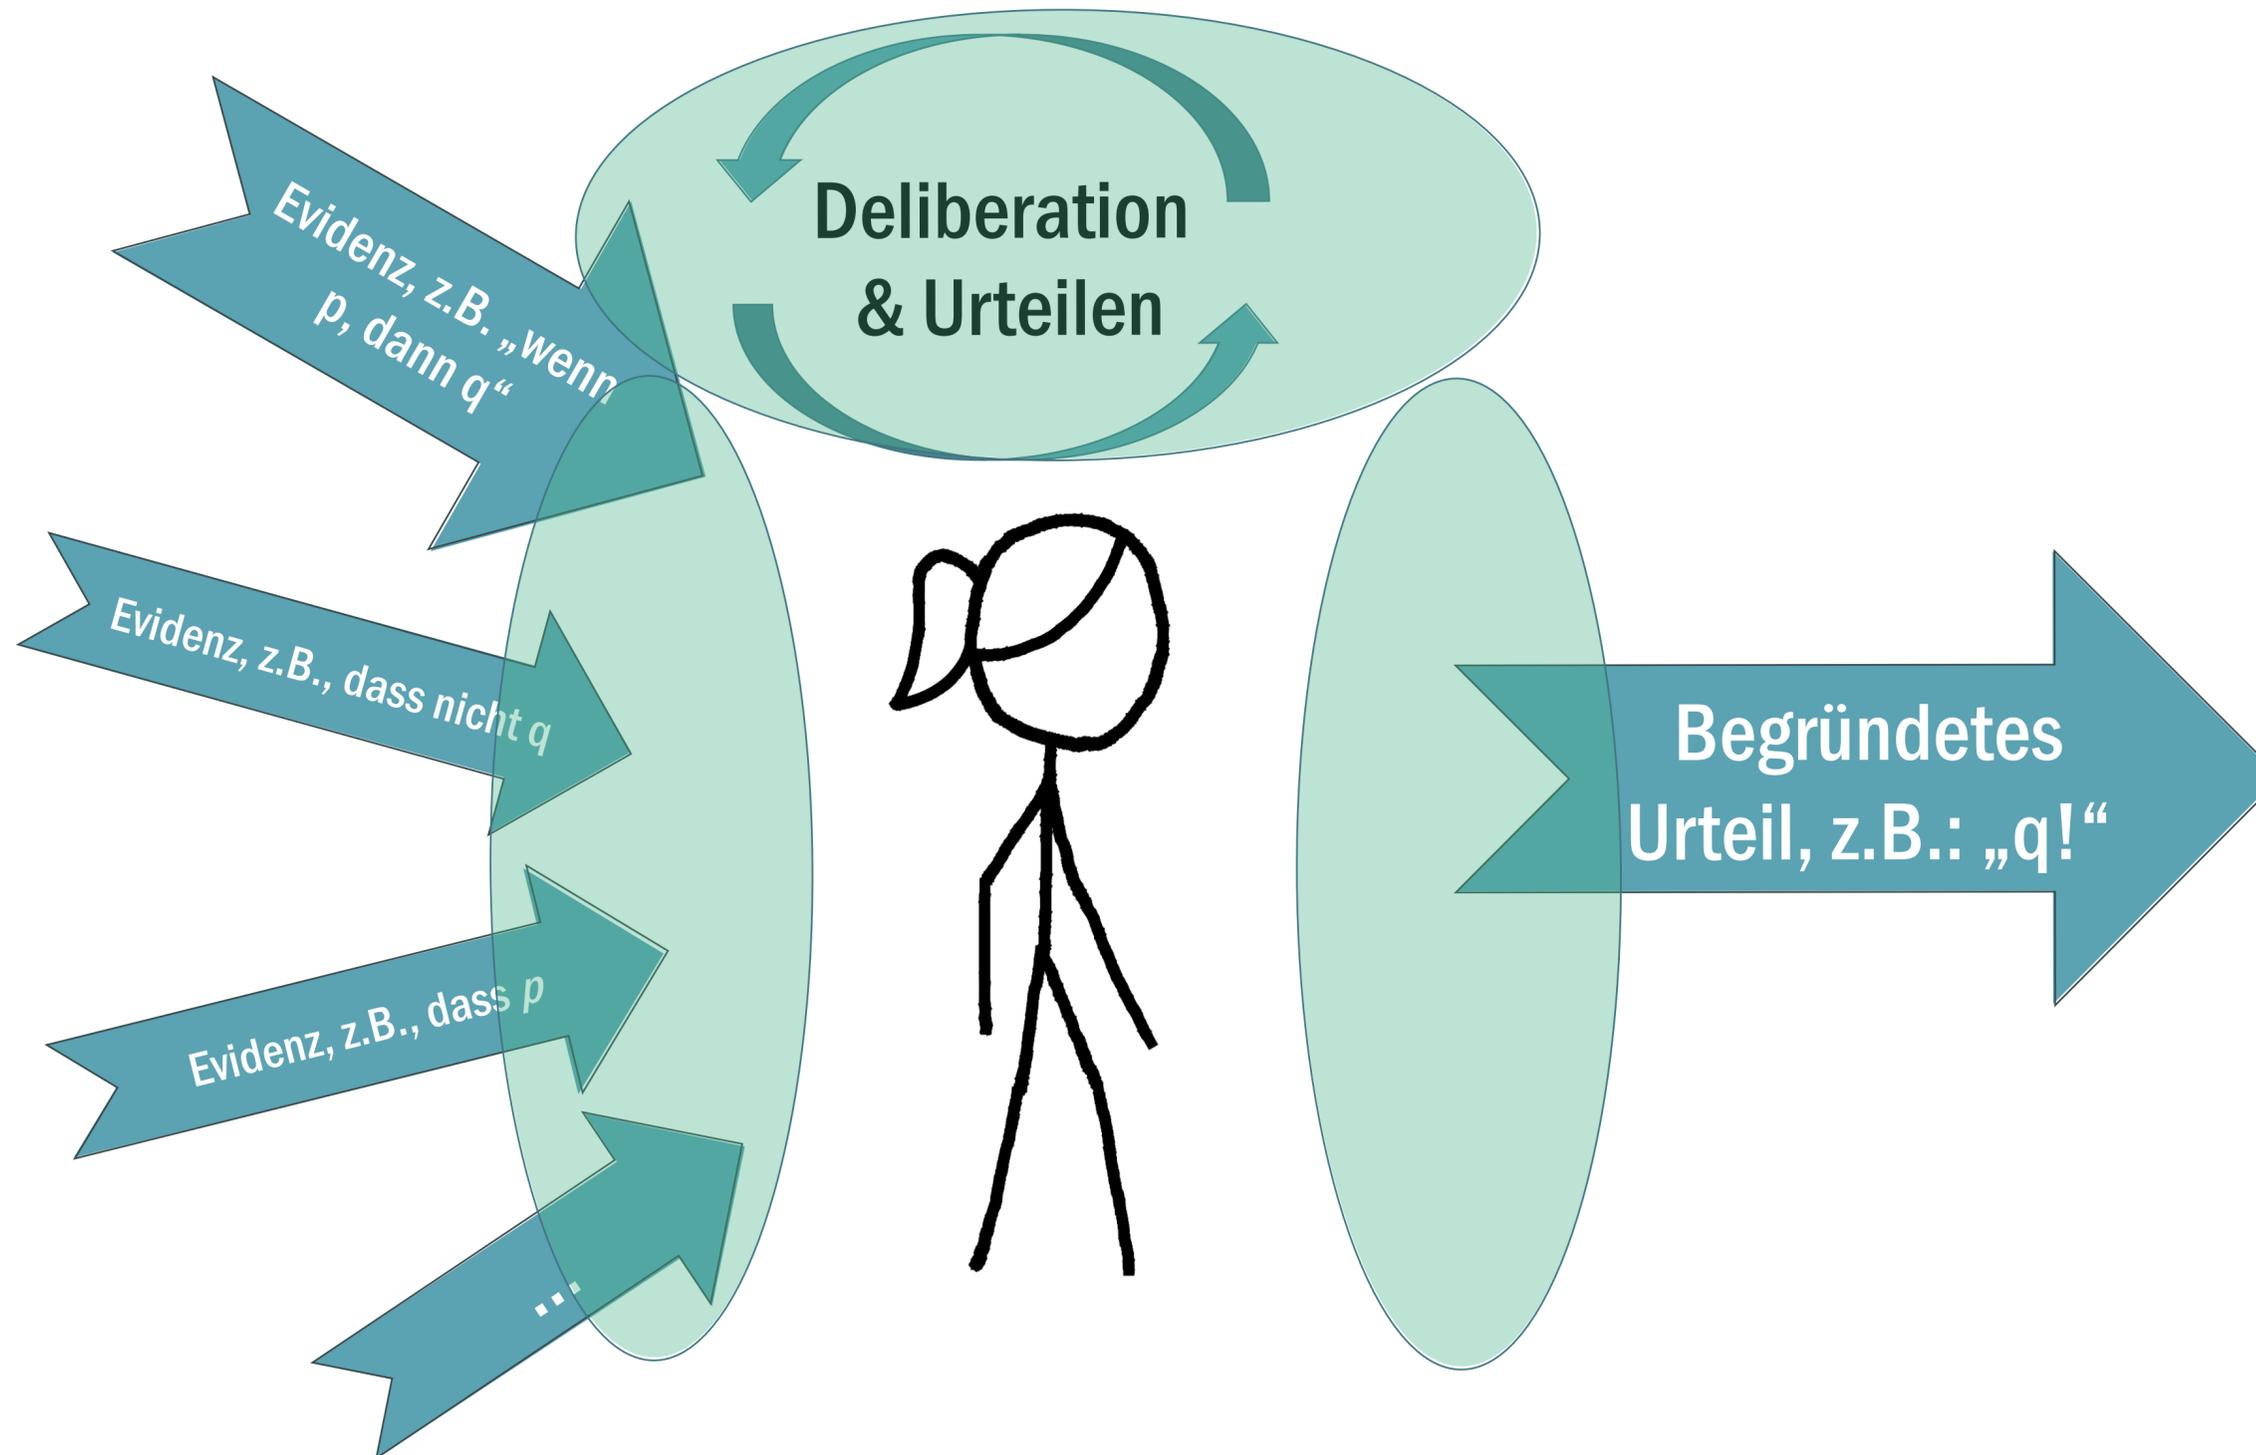
Typ-2-Transparenz: Relevante Perspektiven



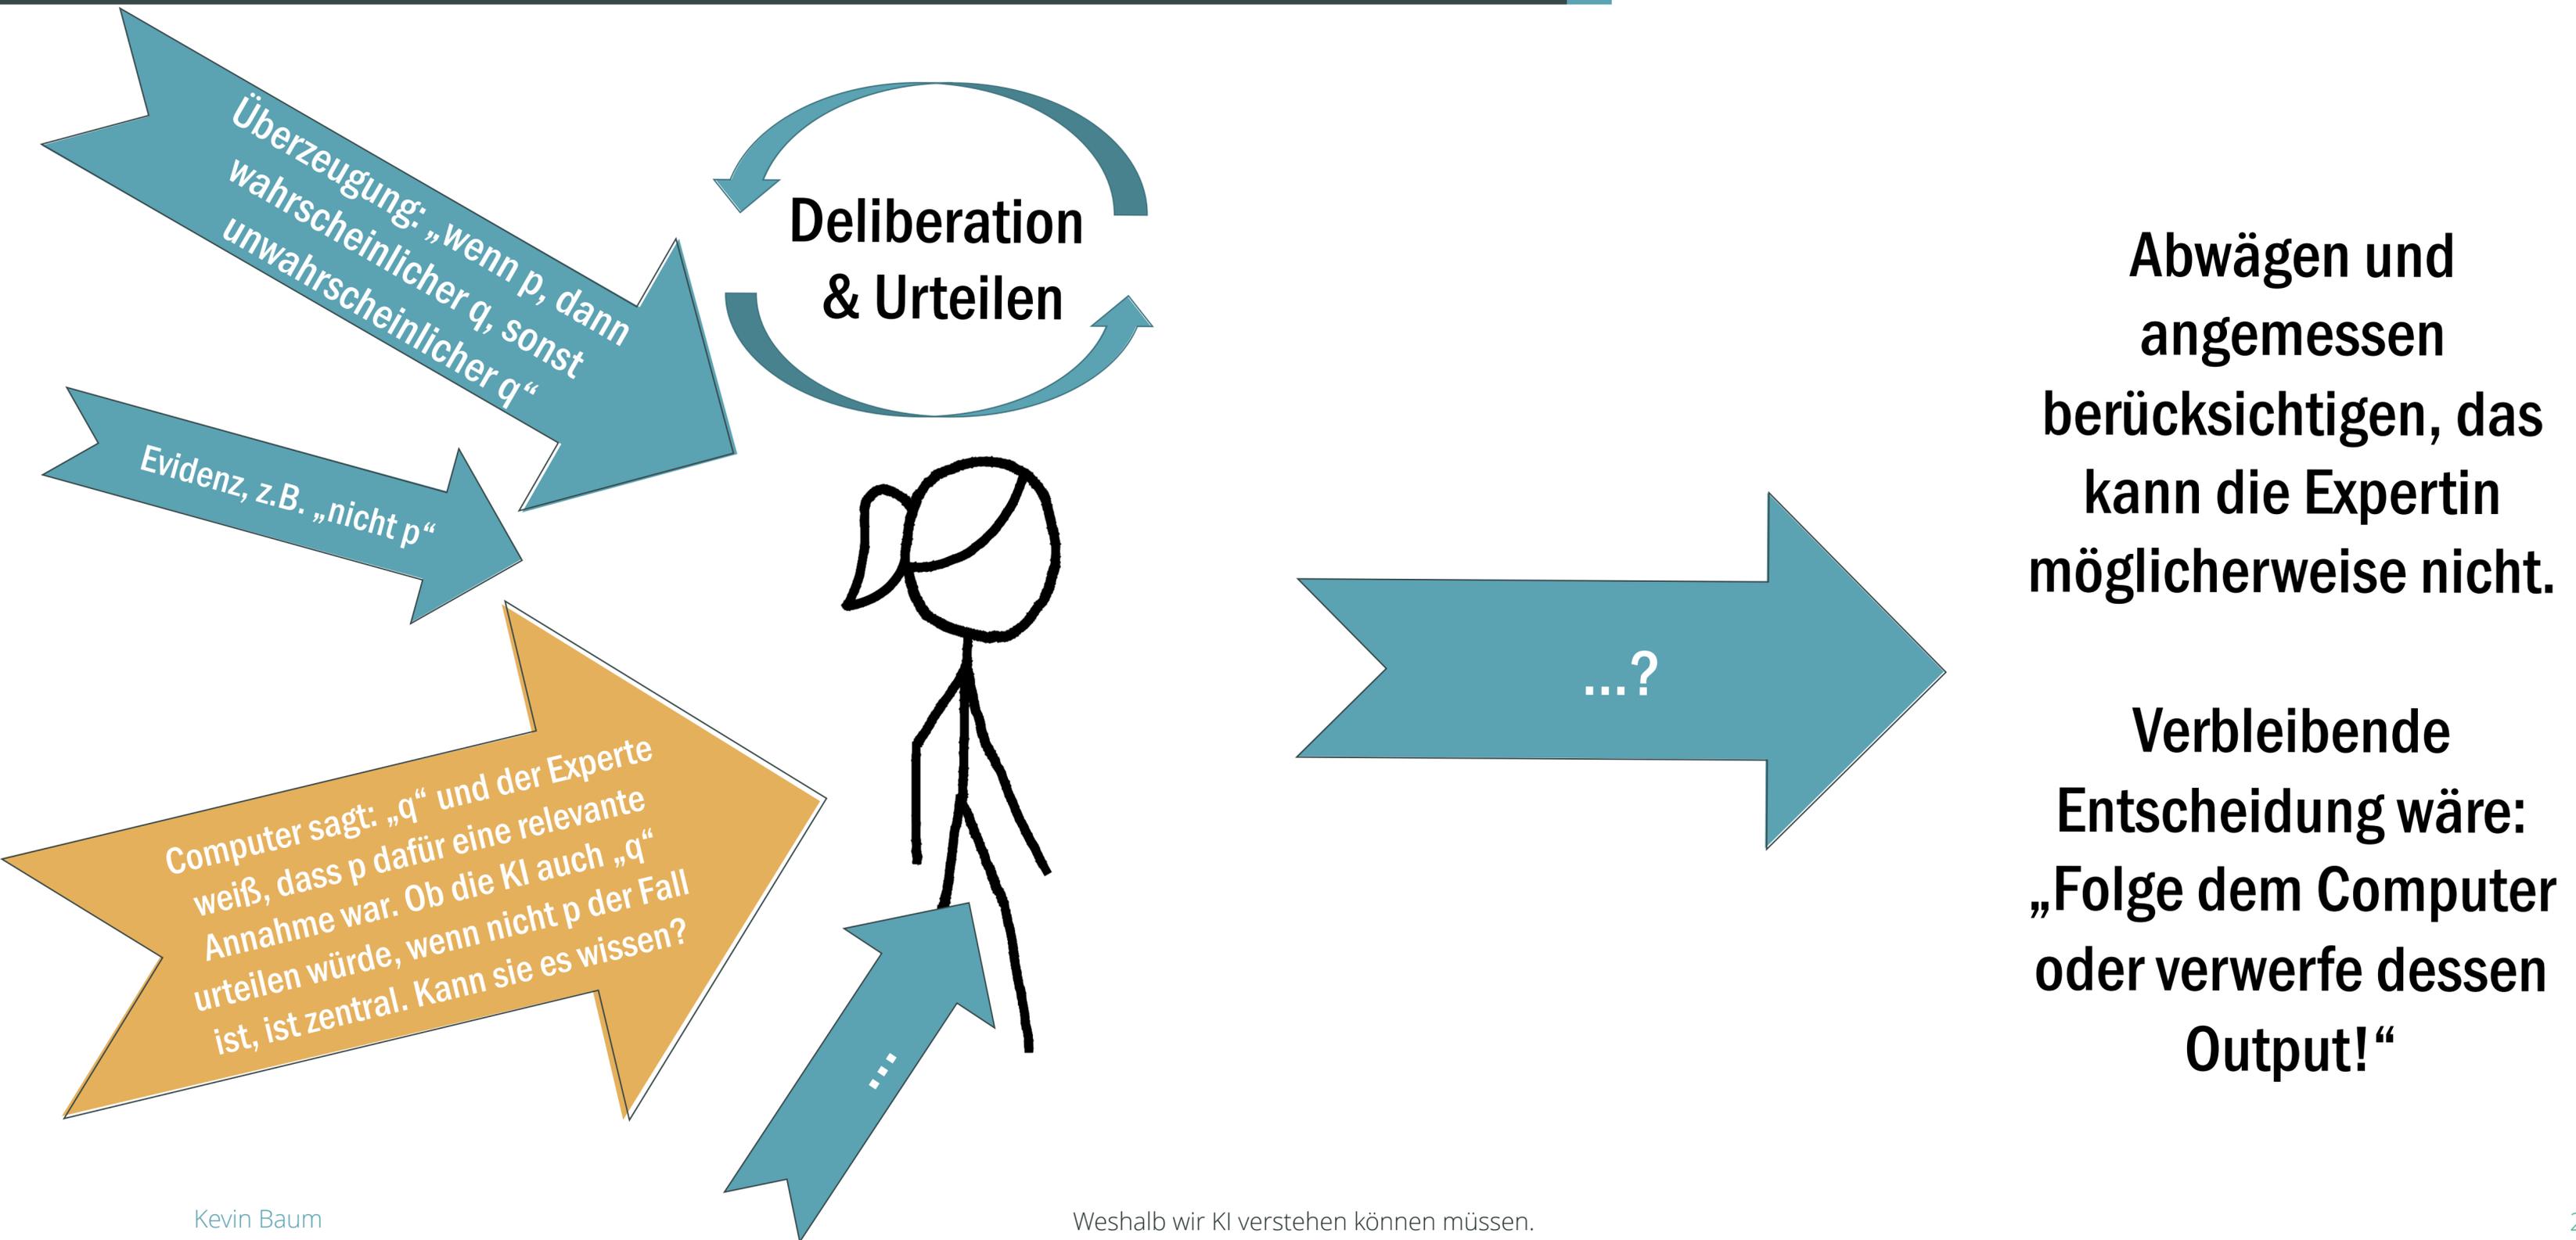
Typ-3-Transparenz: Relevante Perspektiven



Die Funktion menschlicher Entscheider

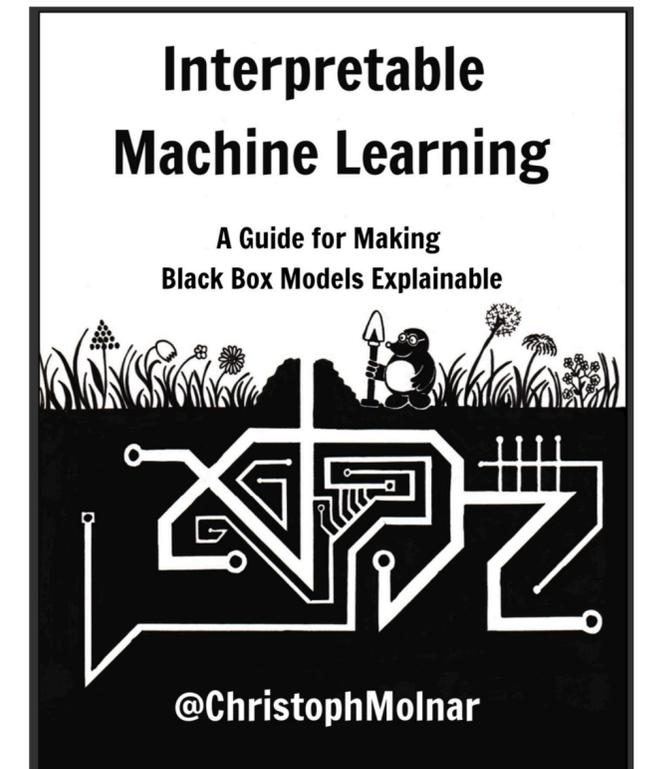


Das ganz-oder-gar-nicht-Problem



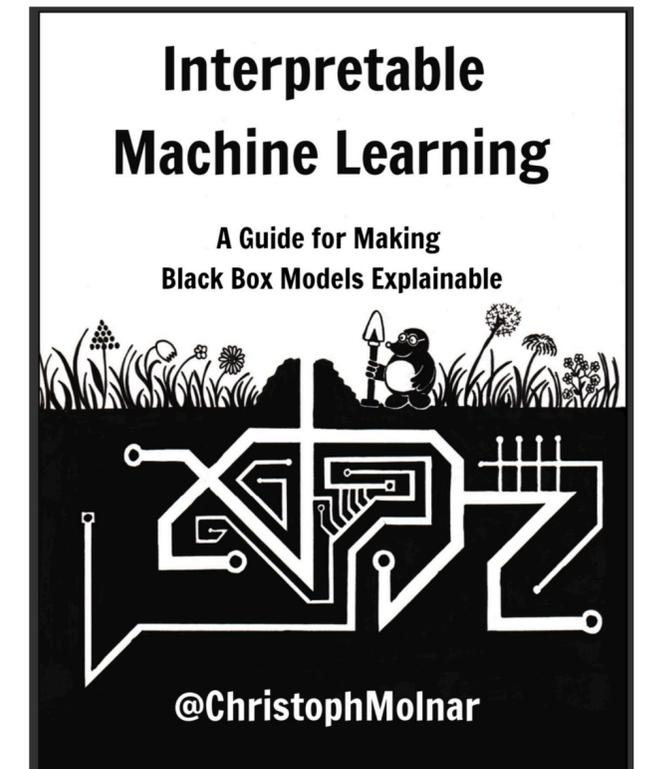
Bedarf: Erklärungen

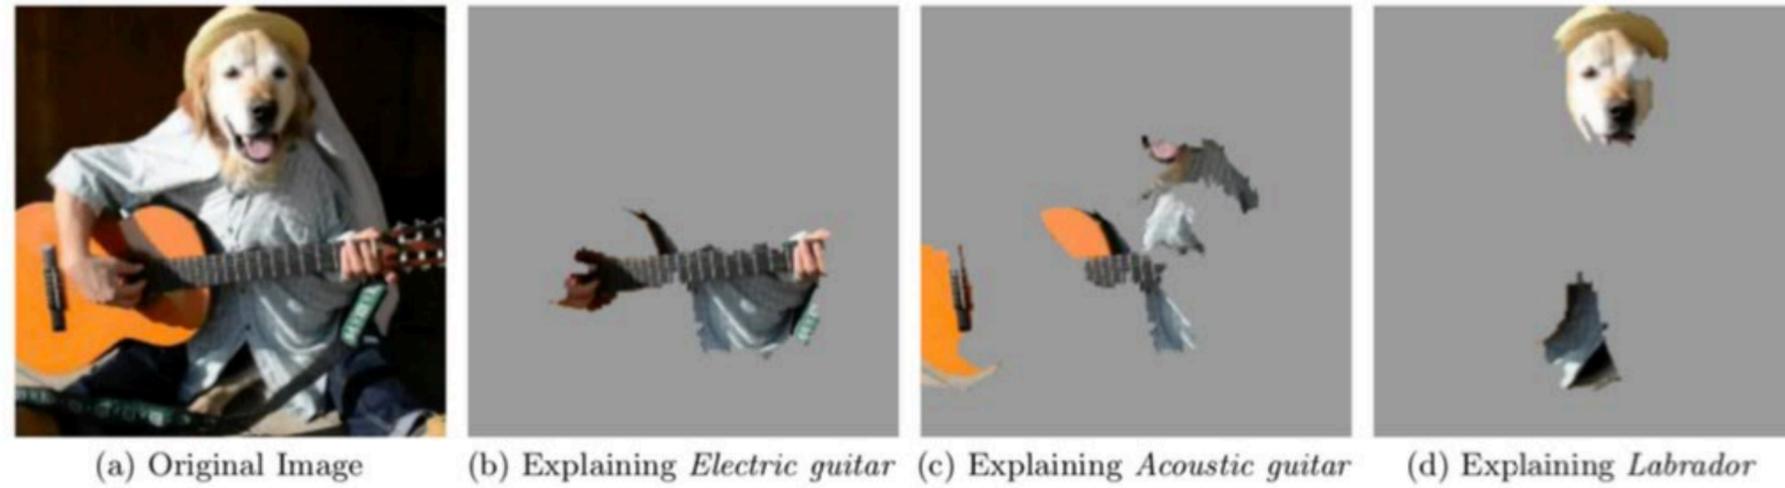
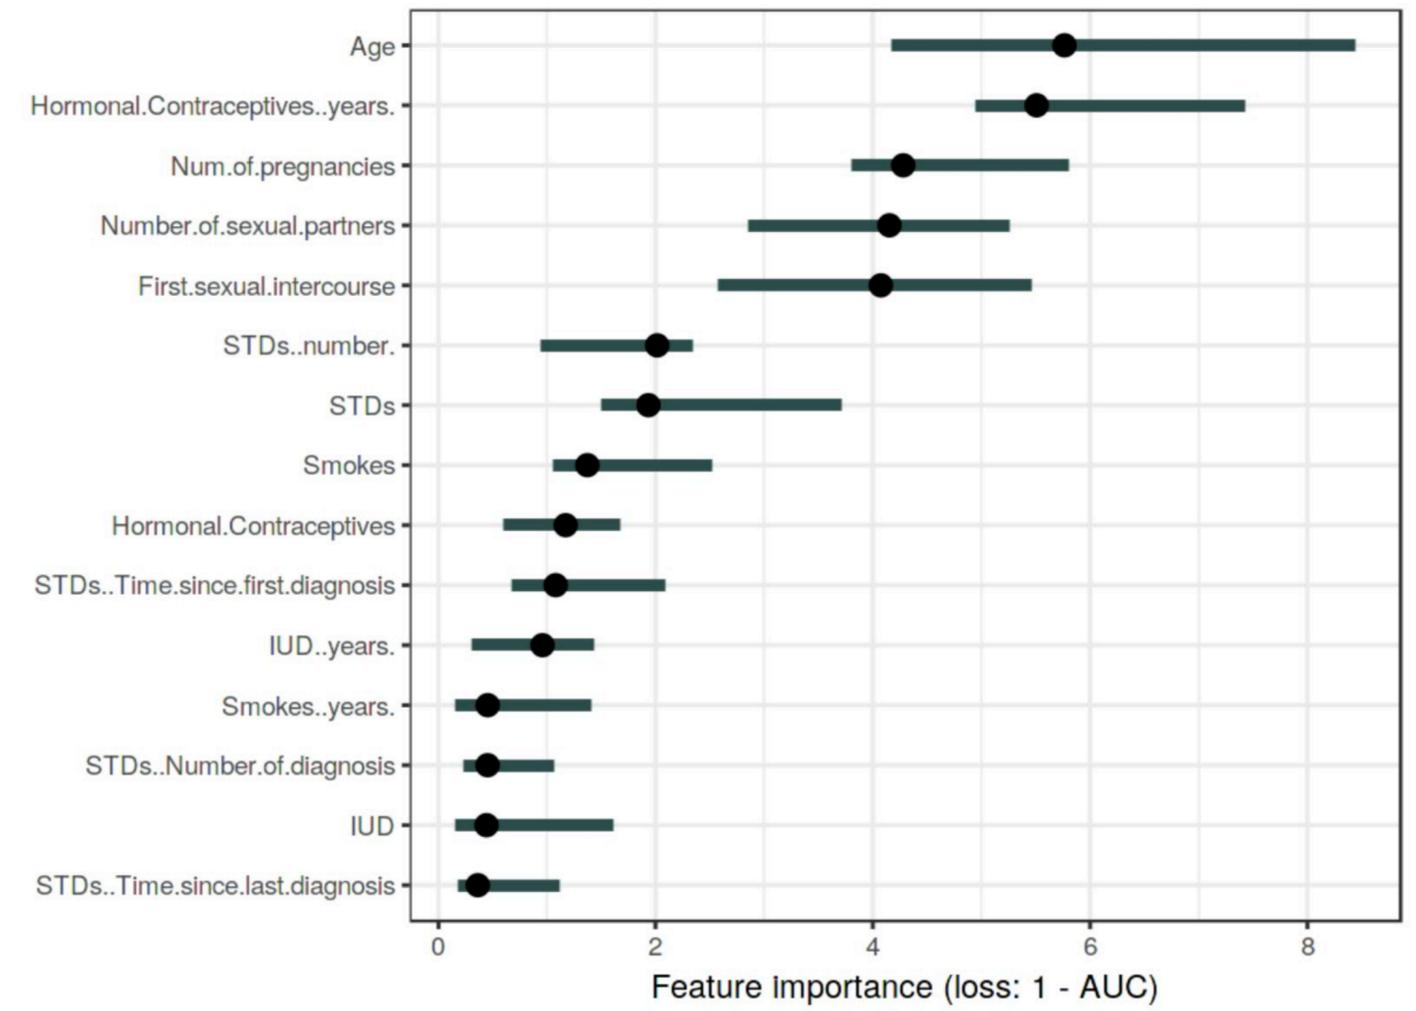
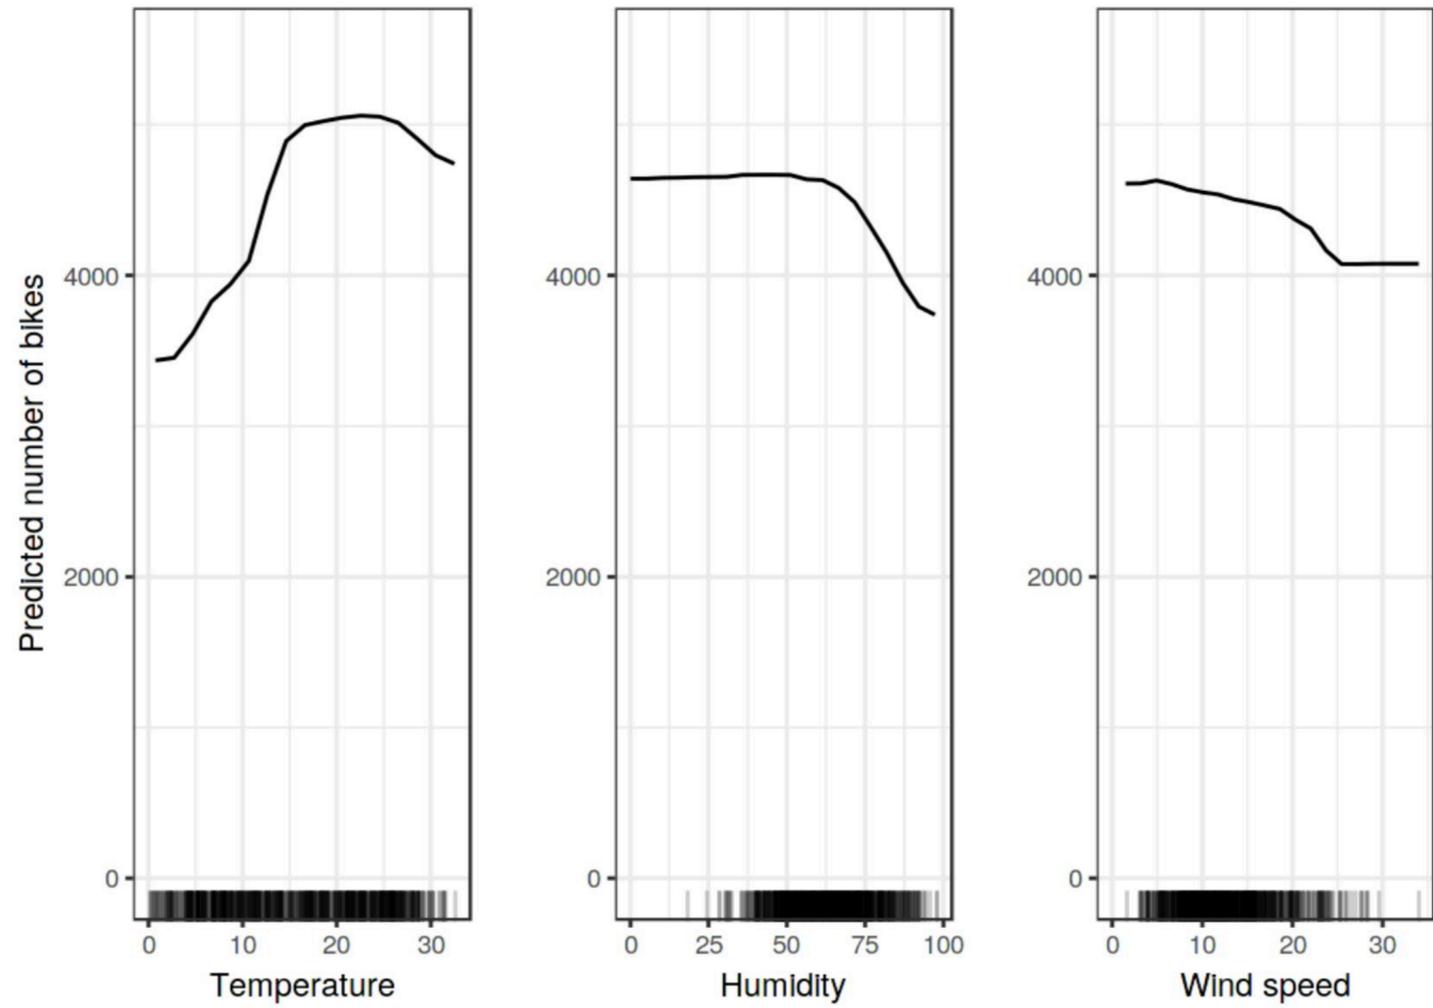
- Hier stellen sich notwendigerweise „Warum-Fragen“
 - „Warum bewertet es diesen Bewerber so gut/so schlecht?“
 - „Warum ist Bewerber A, der zu Minderheit X gehört, vor Bewerber B gerankt?“
 - ...
- Warum-Fragen wollen als Antwort Erklärungen.
- Wir benötigen Antworten auf Erklärungen.



Bedarf: Erklärungen

- Wir benötigen Antworten auf Erklärungen:
Modell-agnostische Methoden vs. Transparenz by Design (erklärbare Modelle)
- Methoden: Nicht alle Antworten müssen dabei verbal sein.
 - Partial Dependence Plot (PDP)
 - Feature Interaction, Feature Importance
 - Global & Local Surrogates (LIME)
 - Example-Based:
 - Counterfactuals, Adversarial Examples, Prototypes & Criticisms
- Rein formale Erklärungen („Mathe“) nennt man *Explikationen*





LIME explanations for the top 3 classes for image classification made by Google's Inception neural network. The example is taken from the LIME paper (Ribeiro et. al., 2016).

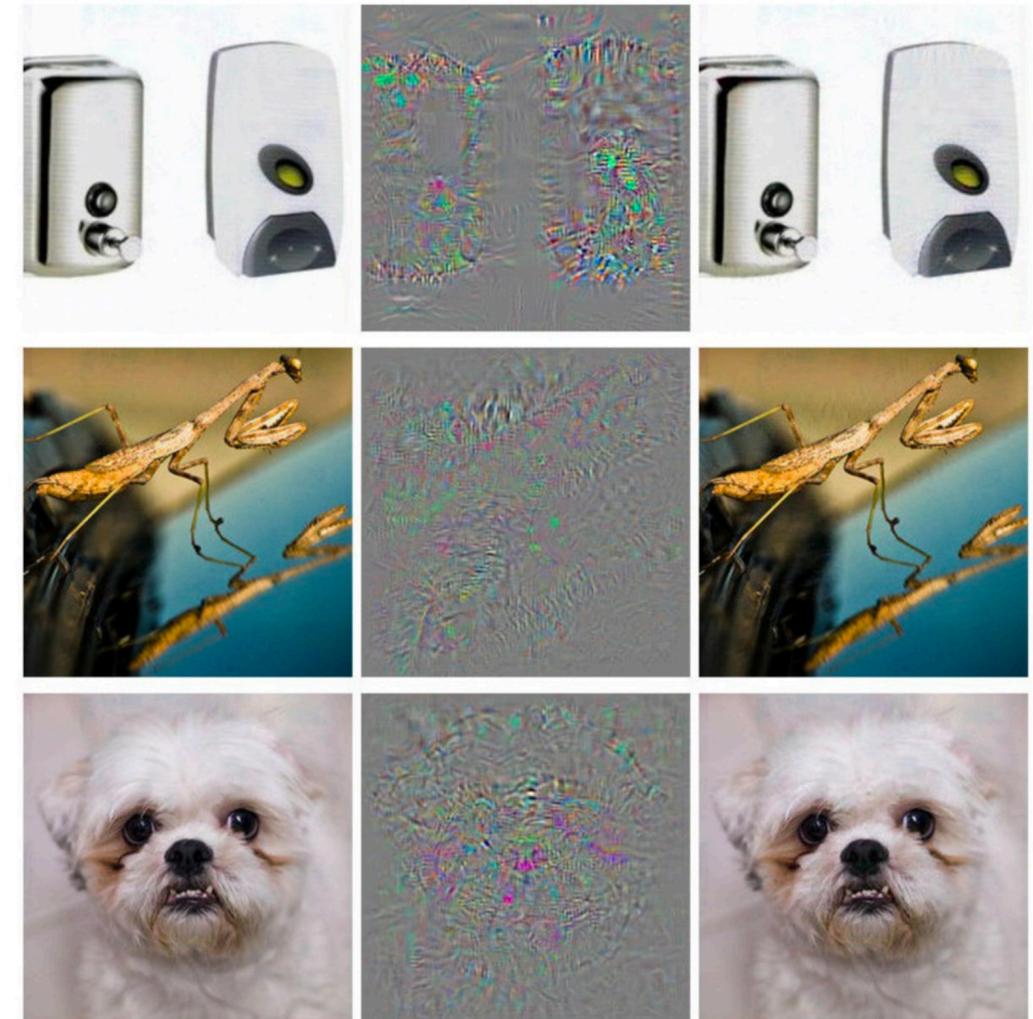
Prototypes



Criticisms



Score	GPA	LSAT	Race	GPA x'	LSAT x'	Race x'
0.17	3.1	39.0	0	3.1	34.0	0
0.54	3.7	48.0	0	3.7	32.4	0
-0.77	3.3	28.0	1	3.3	33.5	0
-0.83	2.4	28.5	1	2.4	35.8	0
-0.57	2.7	18.3	0	2.7	34.9	0



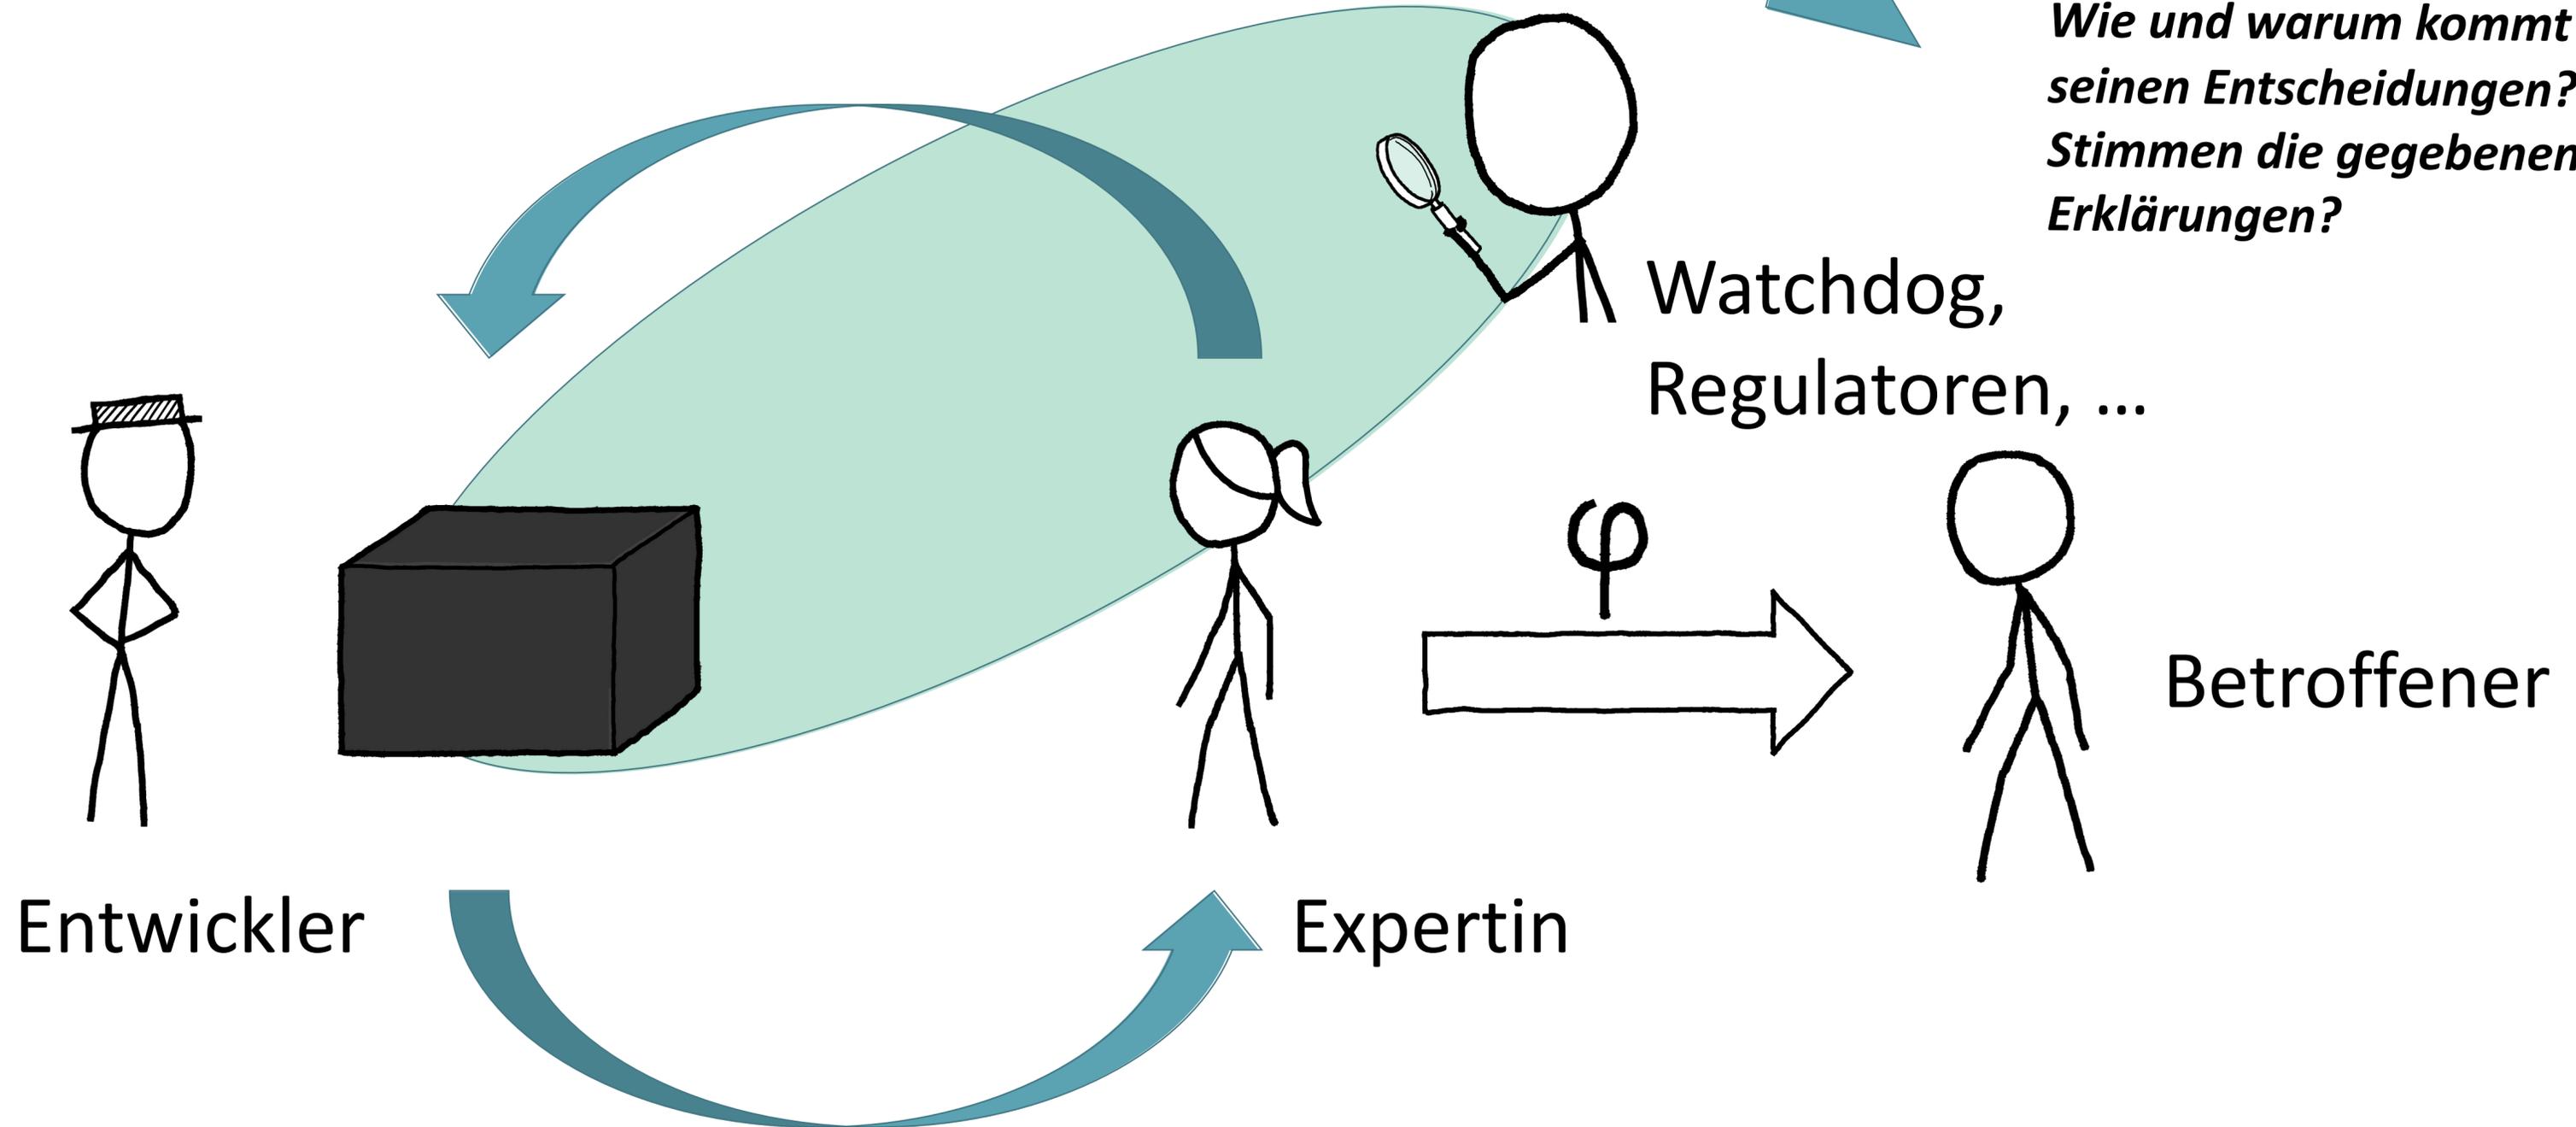
Adversarial examples for AlexNet by Szegedy et. al (2013). All images in the left column are correctly classified. The middle column shows the (magnified) error added to the images to produce the images in the right column all categorized (incorrectly) as 'Ostrich'.

Beschränkungen

- Nur manche Methoden funktionieren für Einzelfälle, d.h.
 - Nur manche Methoden erklären einen bestimmten Ausgabe gegeben eine bestimmte Eingabe. Beispielsweise *Counterfactuals, Feature Importance*
 - Viele Methoden geben eher *Einsicht in das Modell*: was es gut kann, was schlecht. Beispielsweise: *Adversarial Examples, Prototyps & Criticisms, Feature Interaction*
- Die Methoden bieten vor allem Einsichten für visuelle Inputs, Bilder & Videos. Nicht ideal für Verwaltungsaufgaben.
- Sonst braucht es oft eher mathematisches Know-How. Hilfreich für Informatiker und Menschen mit Mathe-Background, eher ungeeignet für Fachexperten (Sachbearbeiter, Richter)

Typ-2-Transparenz: Relevante Perspektiven

*Erfüllt das System bestimmte Anforderungen? Z.B.:
Benachteiligt es nicht nach Gruppenzugehörigkeit? (Fairness)
Wie und warum kommt es zu seinen Entscheidungen?
Stimmen die gegebenen Erklärungen?*



Typ 2:

Transparenz durch *Grundlegendes Verstehen*,
Testbarmachung (Validierbarkeit) und *formale Explikation*

Umsetzbarkeit?

- Praktische Hürden (*Betriebs- und Geschäftsgeheimnisse, Aufwand*):
Bedarf einer *vertrauenswürdigen*, kompetenten und unabhängigen Prüfstelle („Algorithmen-TÜV“), Regulierung
- Theoretisch u.U. sehr anspruchsvoll bis unmöglich
(für moderne *Machine-Learning-Verfahren*)

Typ 2:

Transparenz durch *Grundlegendes Verstehen*,
Testbarmachung (Validierbarkeit) und *formale Explikation*

Warum wichtig?

- *Scheinobjektivierung (Mathwashing)* nicht ‚auf den Leim‘ gehen
- Kontrolle von Modellen, z.B. Erkennen systematischer & statistischer Fehler
- Teilweise verbesserte Einschätzbarkeit von individuellen Entscheidungen, ermöglicht teilweise Evaluation und Verbesserung (Feedback)

Solange nicht gegeben, dürfen solche Systeme *eigentlich* nicht verwendet werden.

Trade-Offs

Stand heute:

Wasch mir den Pelz, aber mach mich nicht nass!

Einiges spricht dafür, dass Methoden mit höherer Genauigkeit/„fähigere“ Methoden dafür weniger zugänglich sind.

Das heißt keineswegs, dass wir unbedingt nach Genauigkeit optimieren sollten → Weitere Trade-Offs

Fairness

Prädiktive
Genauigkeit

Nachvollzieh-
barkeit der
Entscheidungen



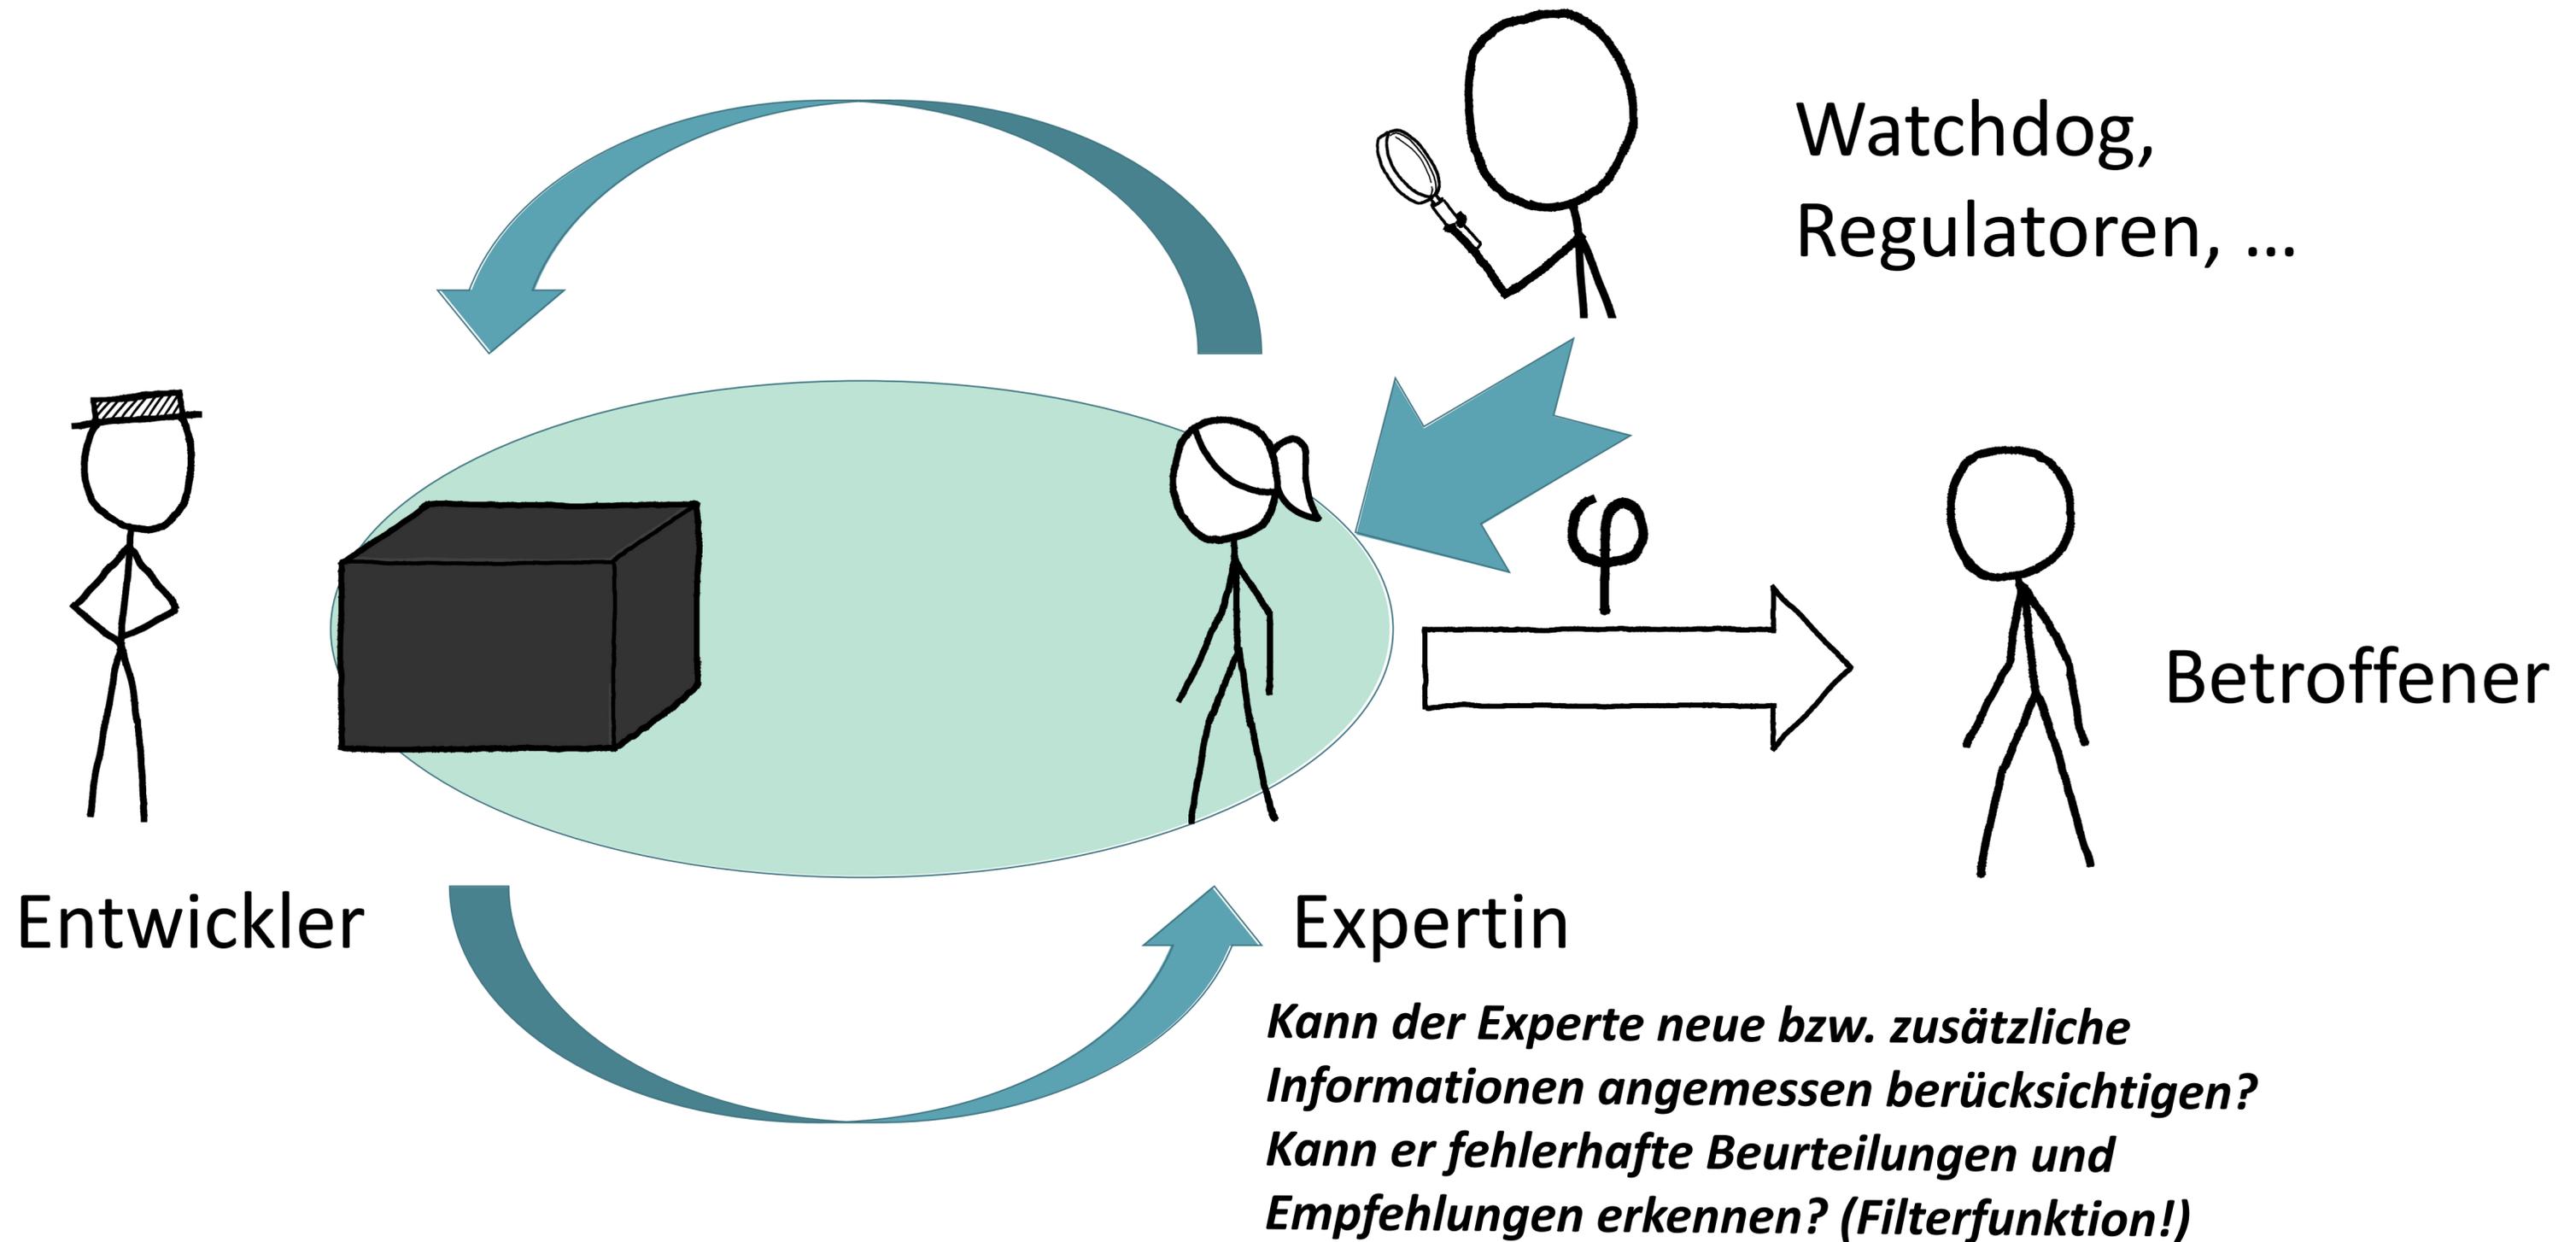
Typ 3:

Transparenz des Entscheidungsprozesses &
Zugang/Zugriff auf den internen, deliberativen Prozess

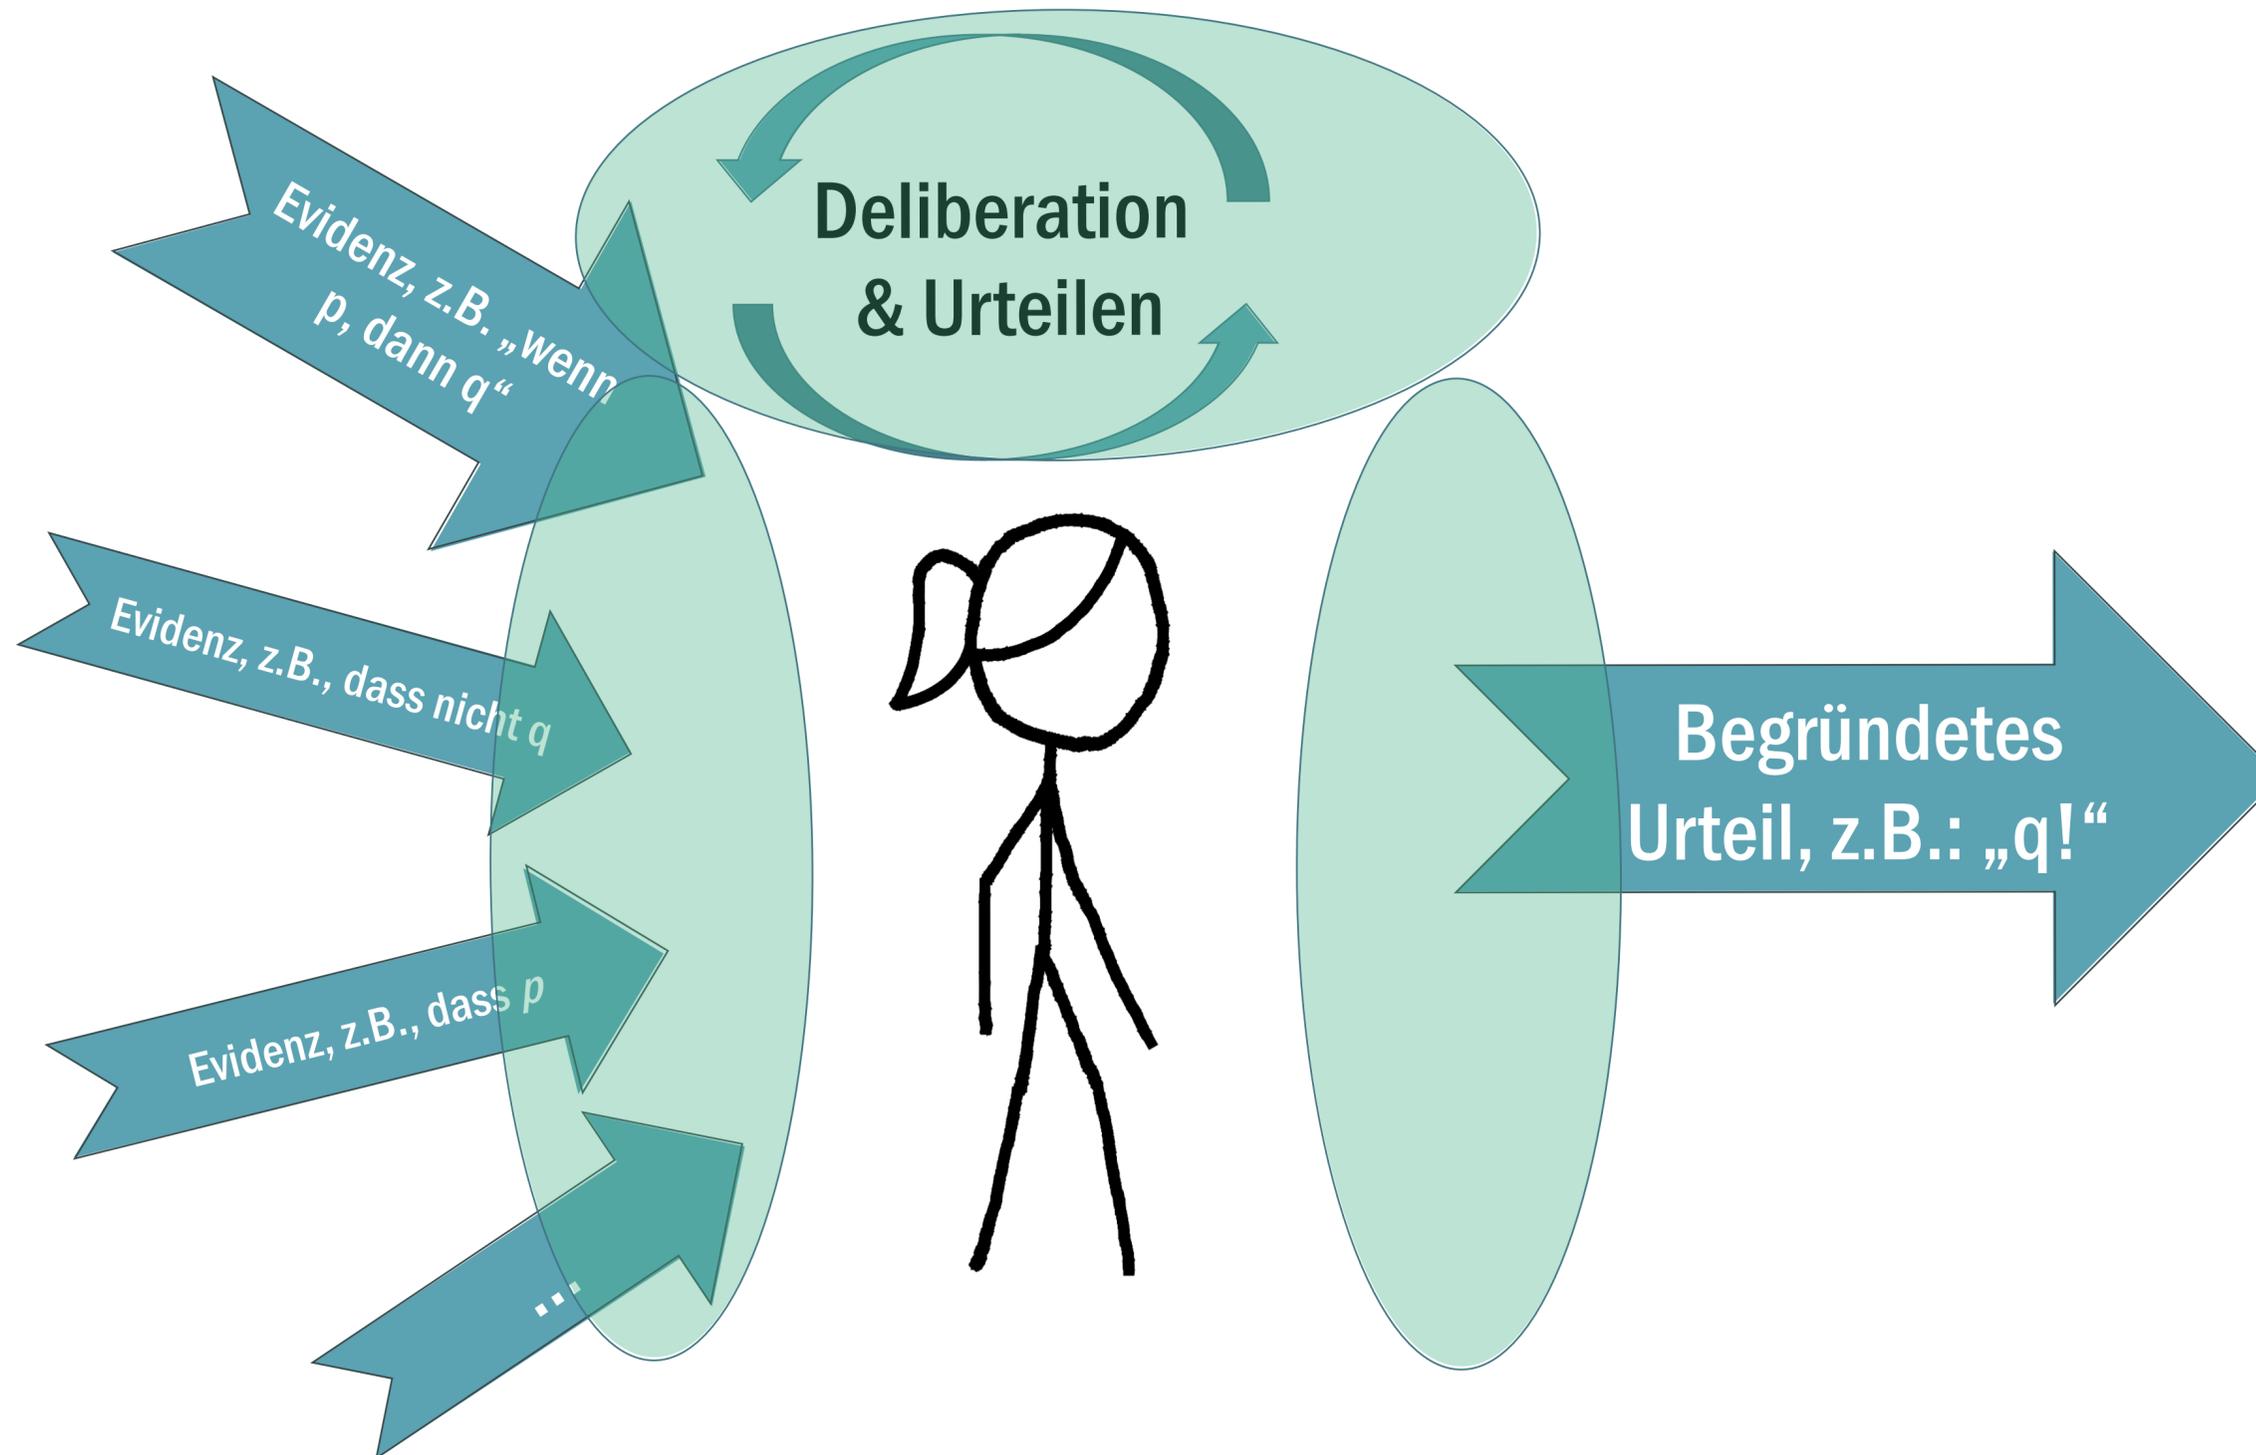
(Gründe, ihre Beziehung zueinander sowie ihre Gewichtung)

Ziel: Individuelle Entscheidung verstehen und hinterfragbar machen

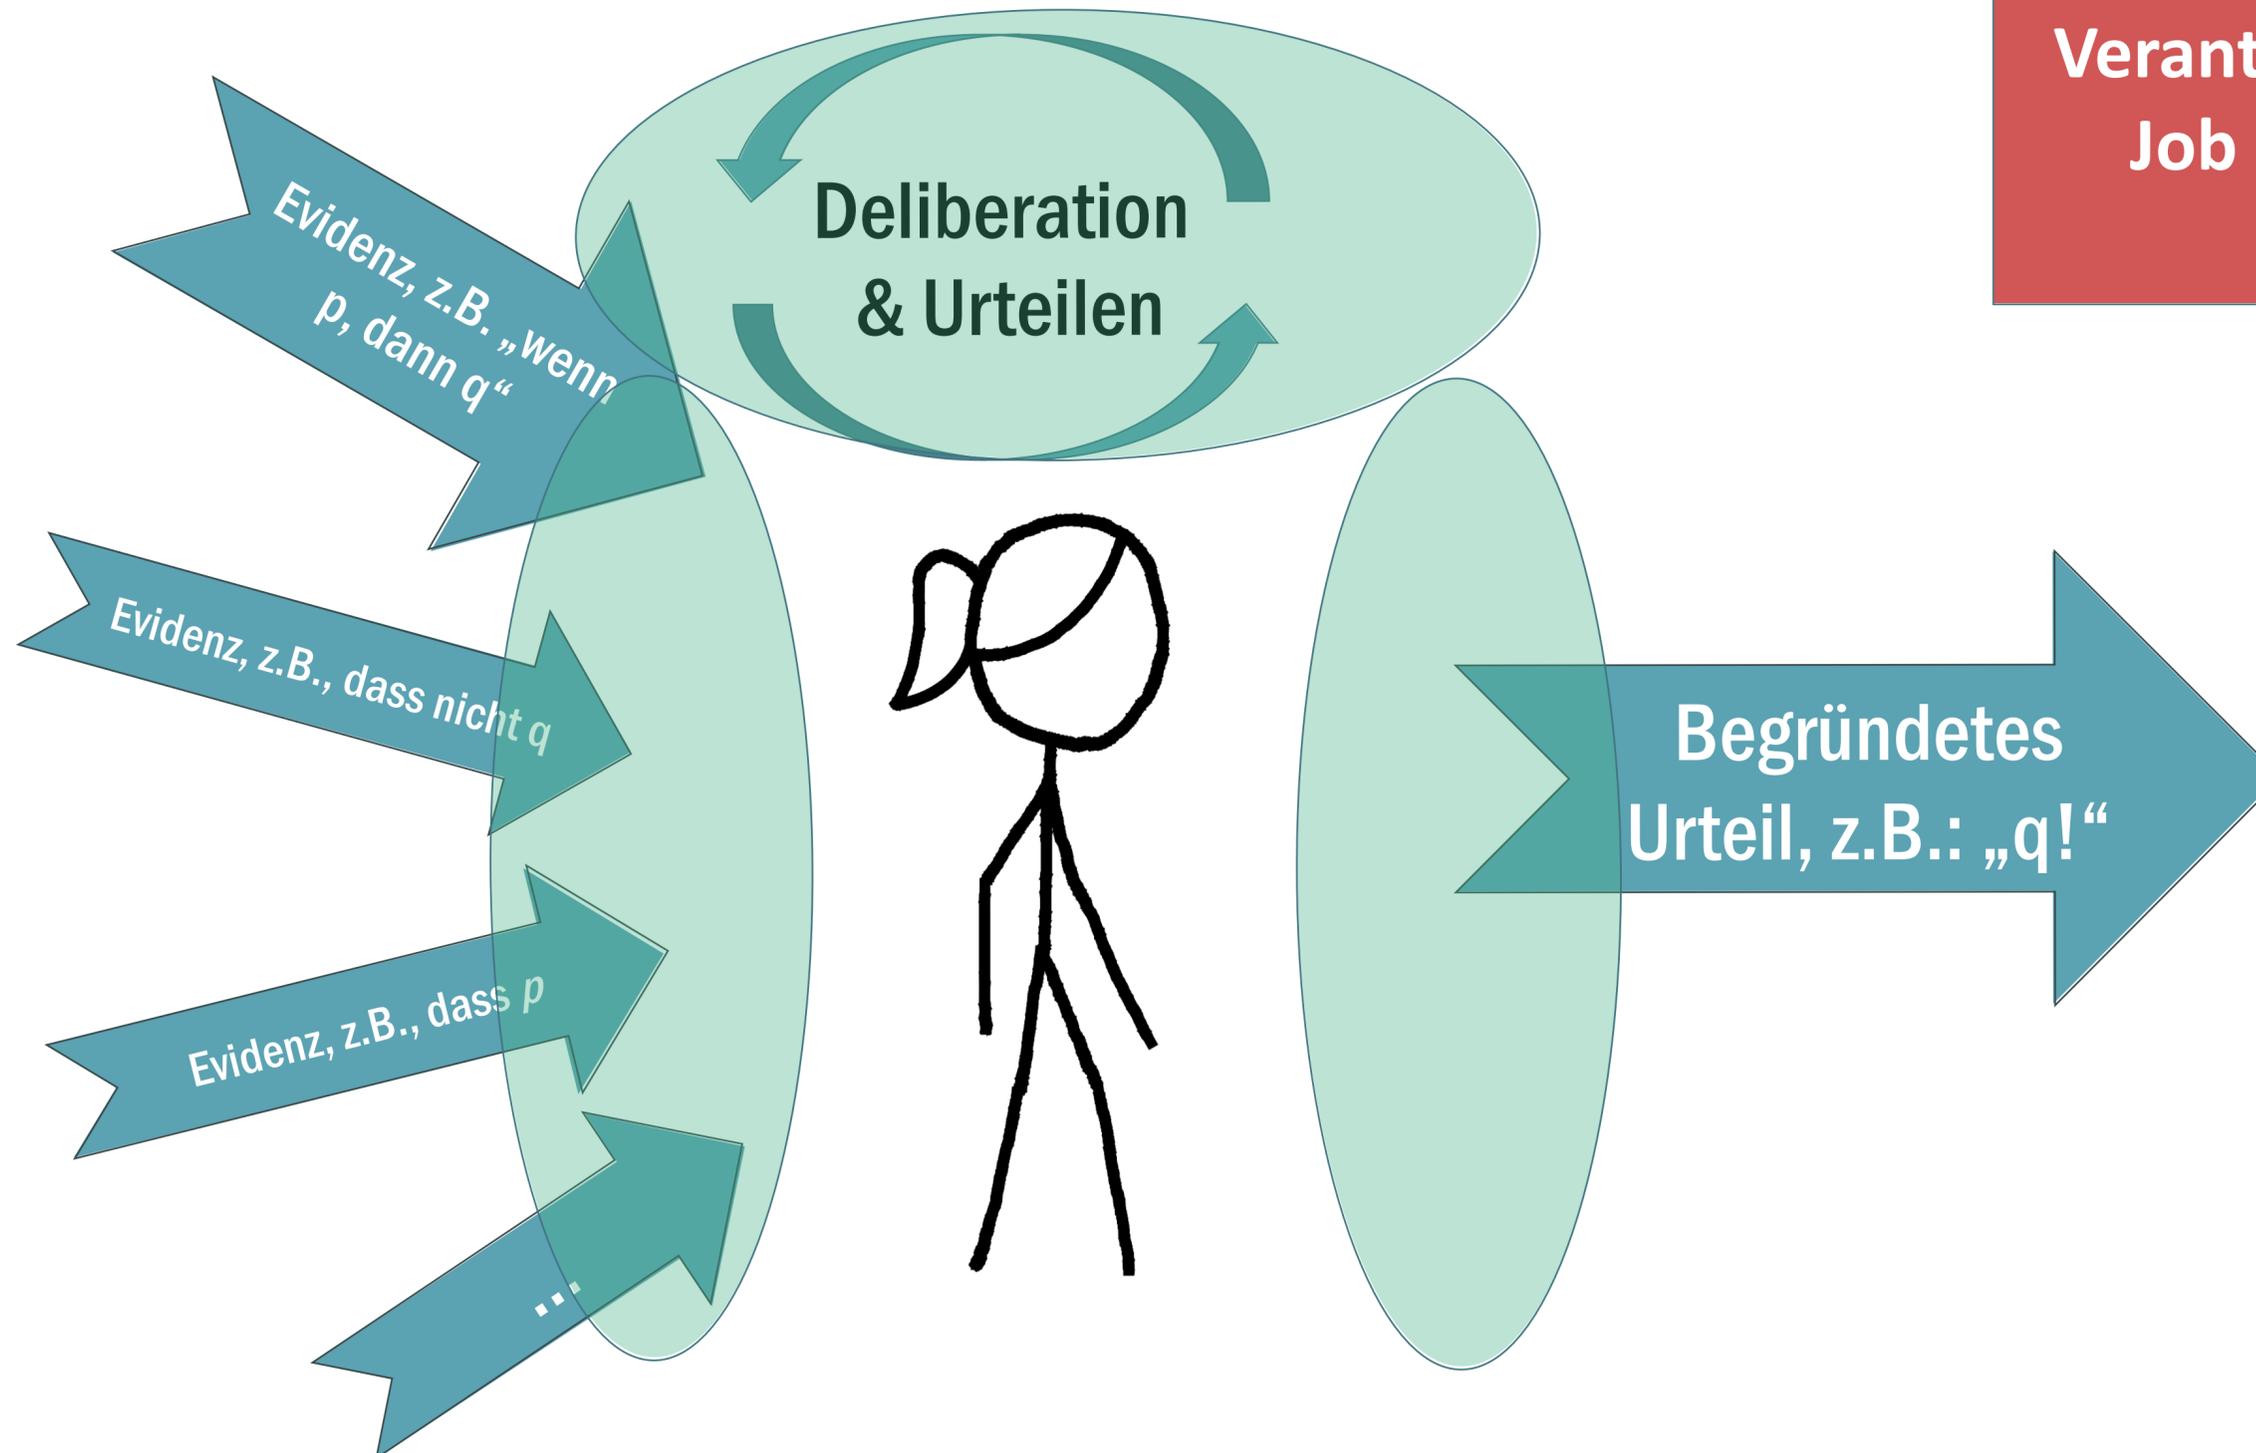
Typ-3-Transparenz: Relevante Perspektiven



Die Funktion menschlicher Entscheider



Die Funktion menschlicher Entscheider

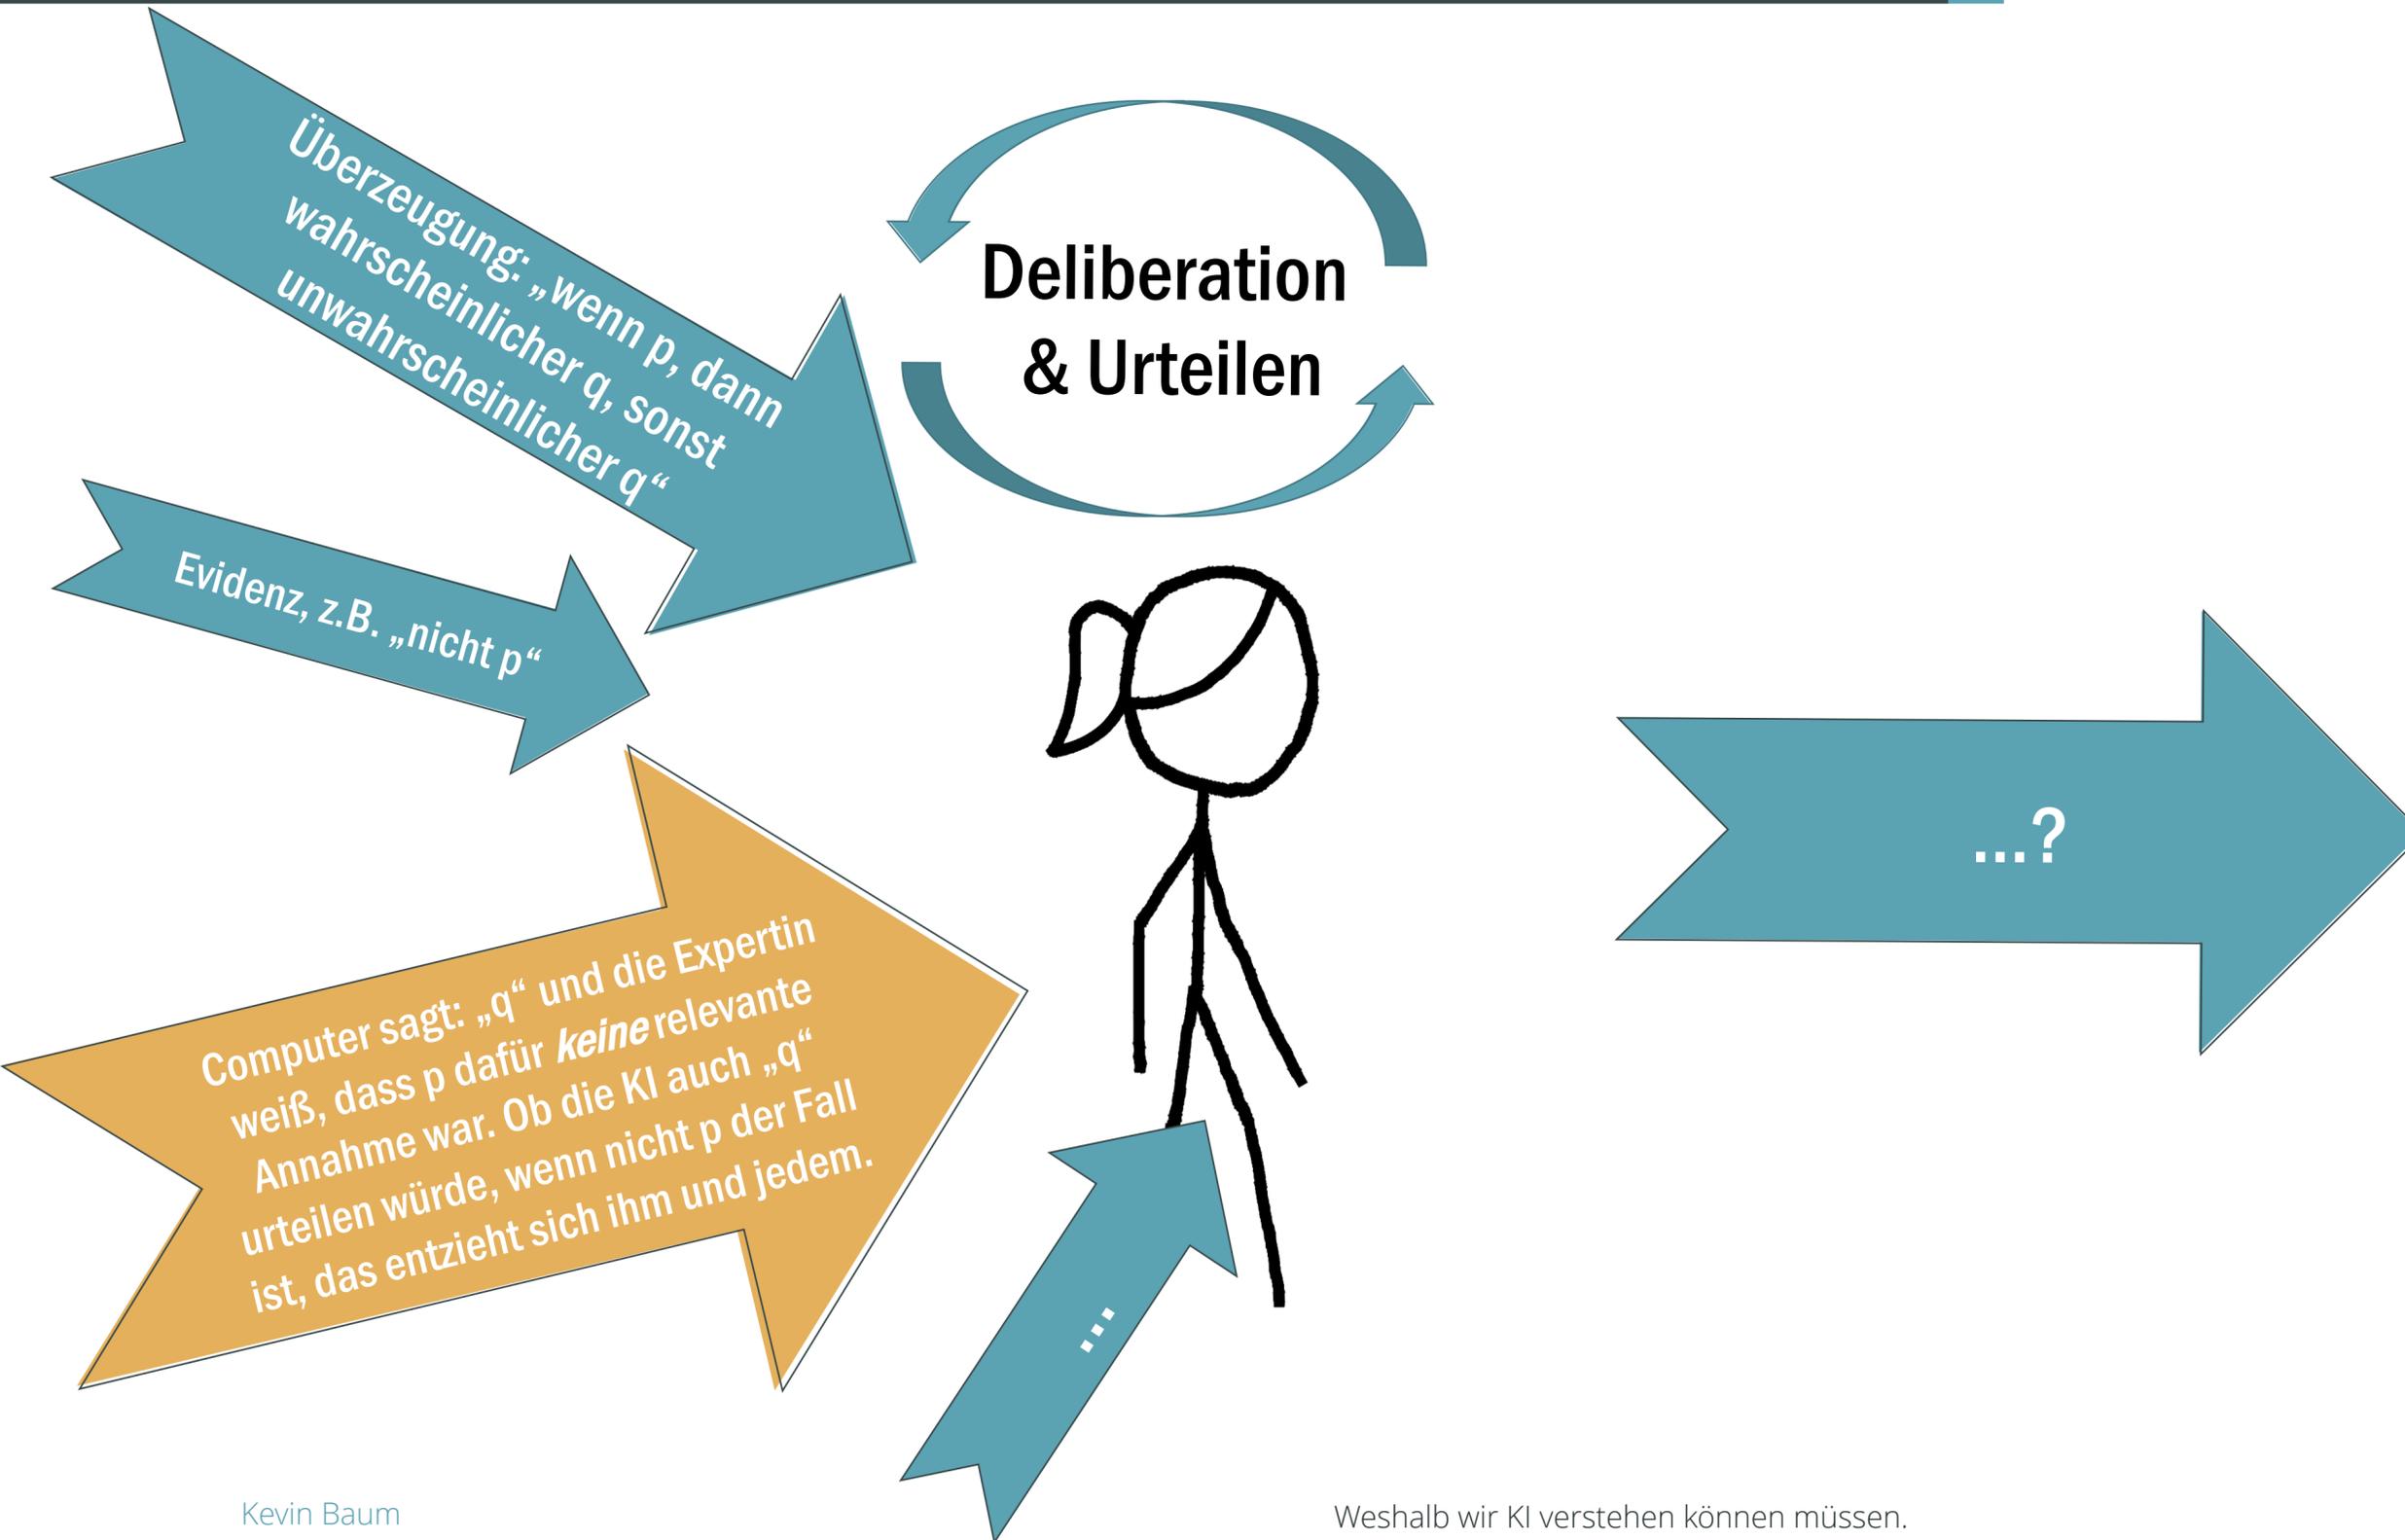


Voraussetzung für
Verantwortung, dafür, seinen
Job machen zu können...

Was tun im Falle sich
widersprechender
Evidenz oder neuer
Informationen?

Reicht es, die Inputs
der Black Box zu
kennen?

Das ganz-oder-gar-nicht-Problem

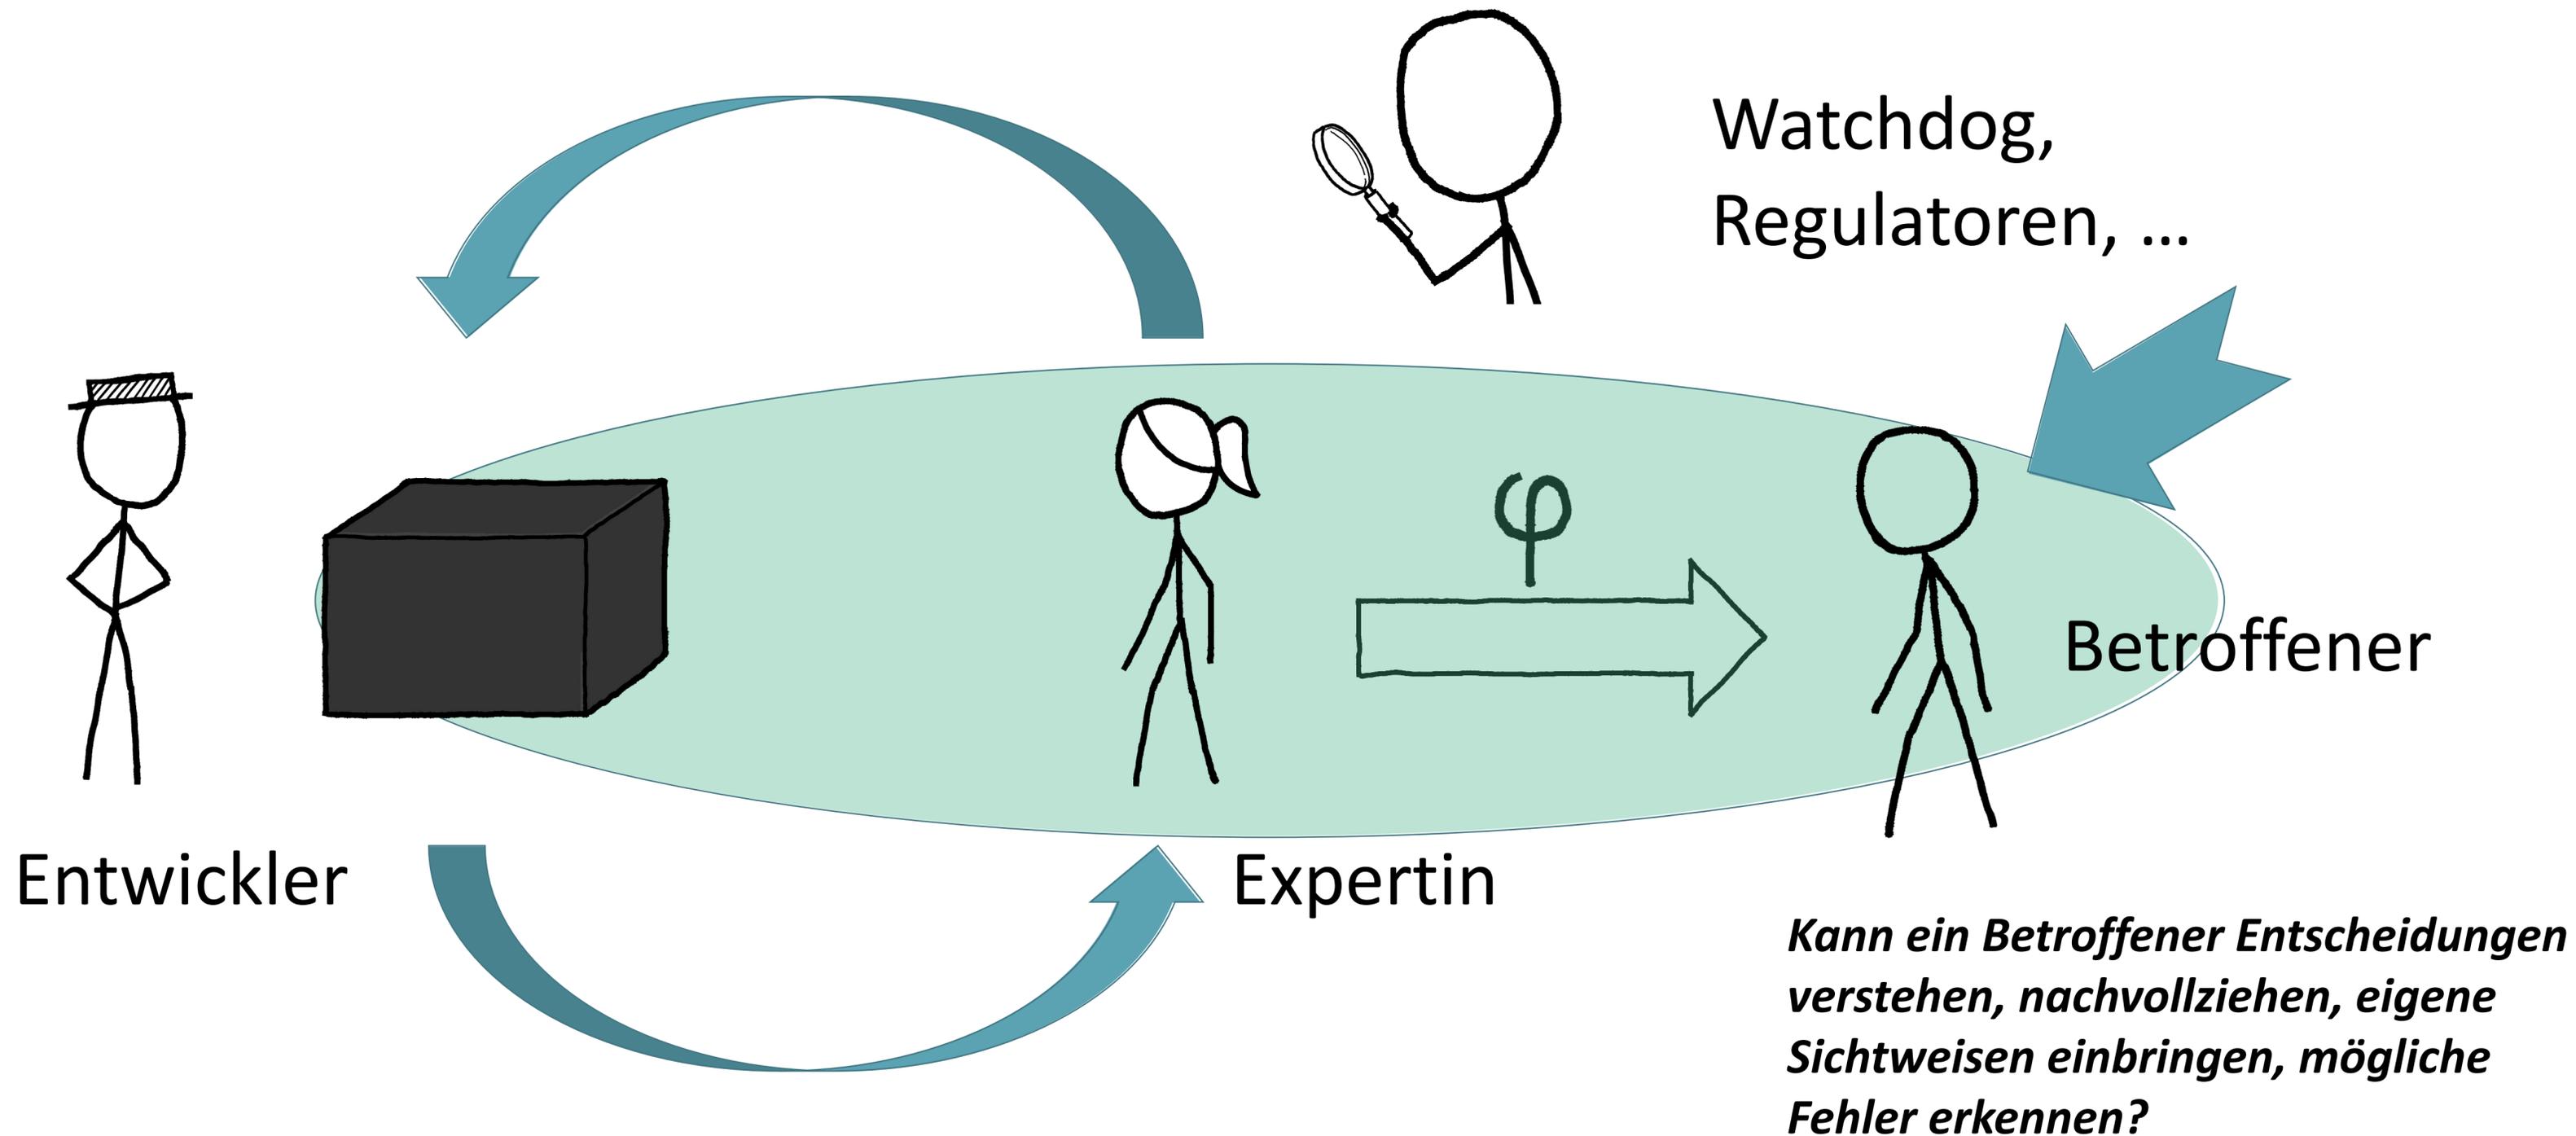


„Folge dem Computer oder eben nicht!“

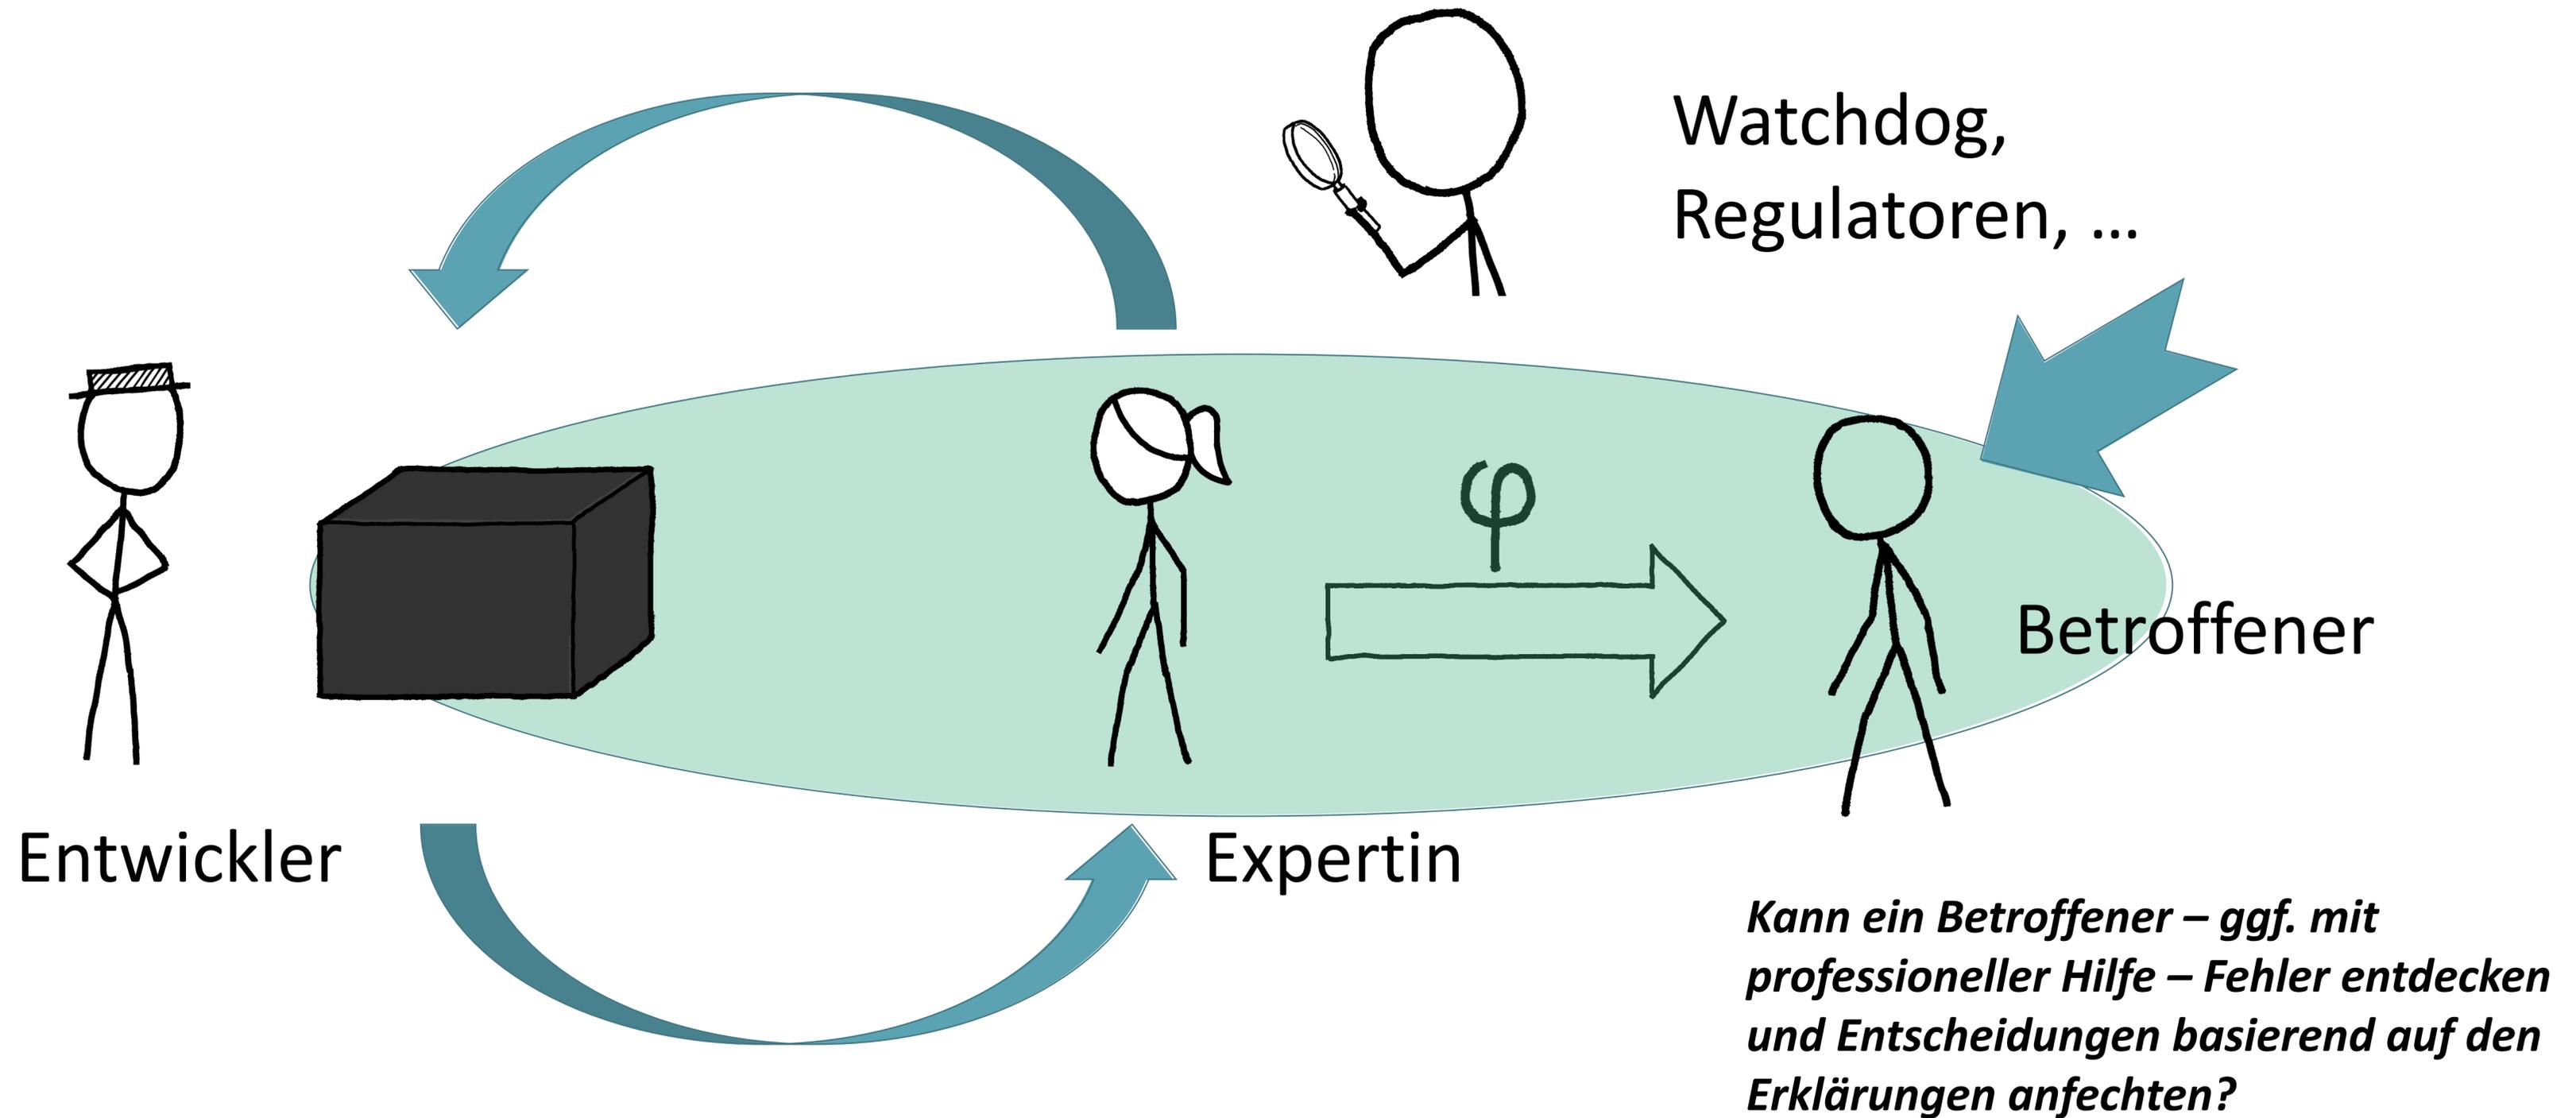
Abwägen und angemessen, teilweise berücksichtigen, kann er nicht.

→ Willfähriger Entscheidungshelfer oder willkürlicher Verweigerer?

Typ-3-Transparenz: Relevante Perspektiven

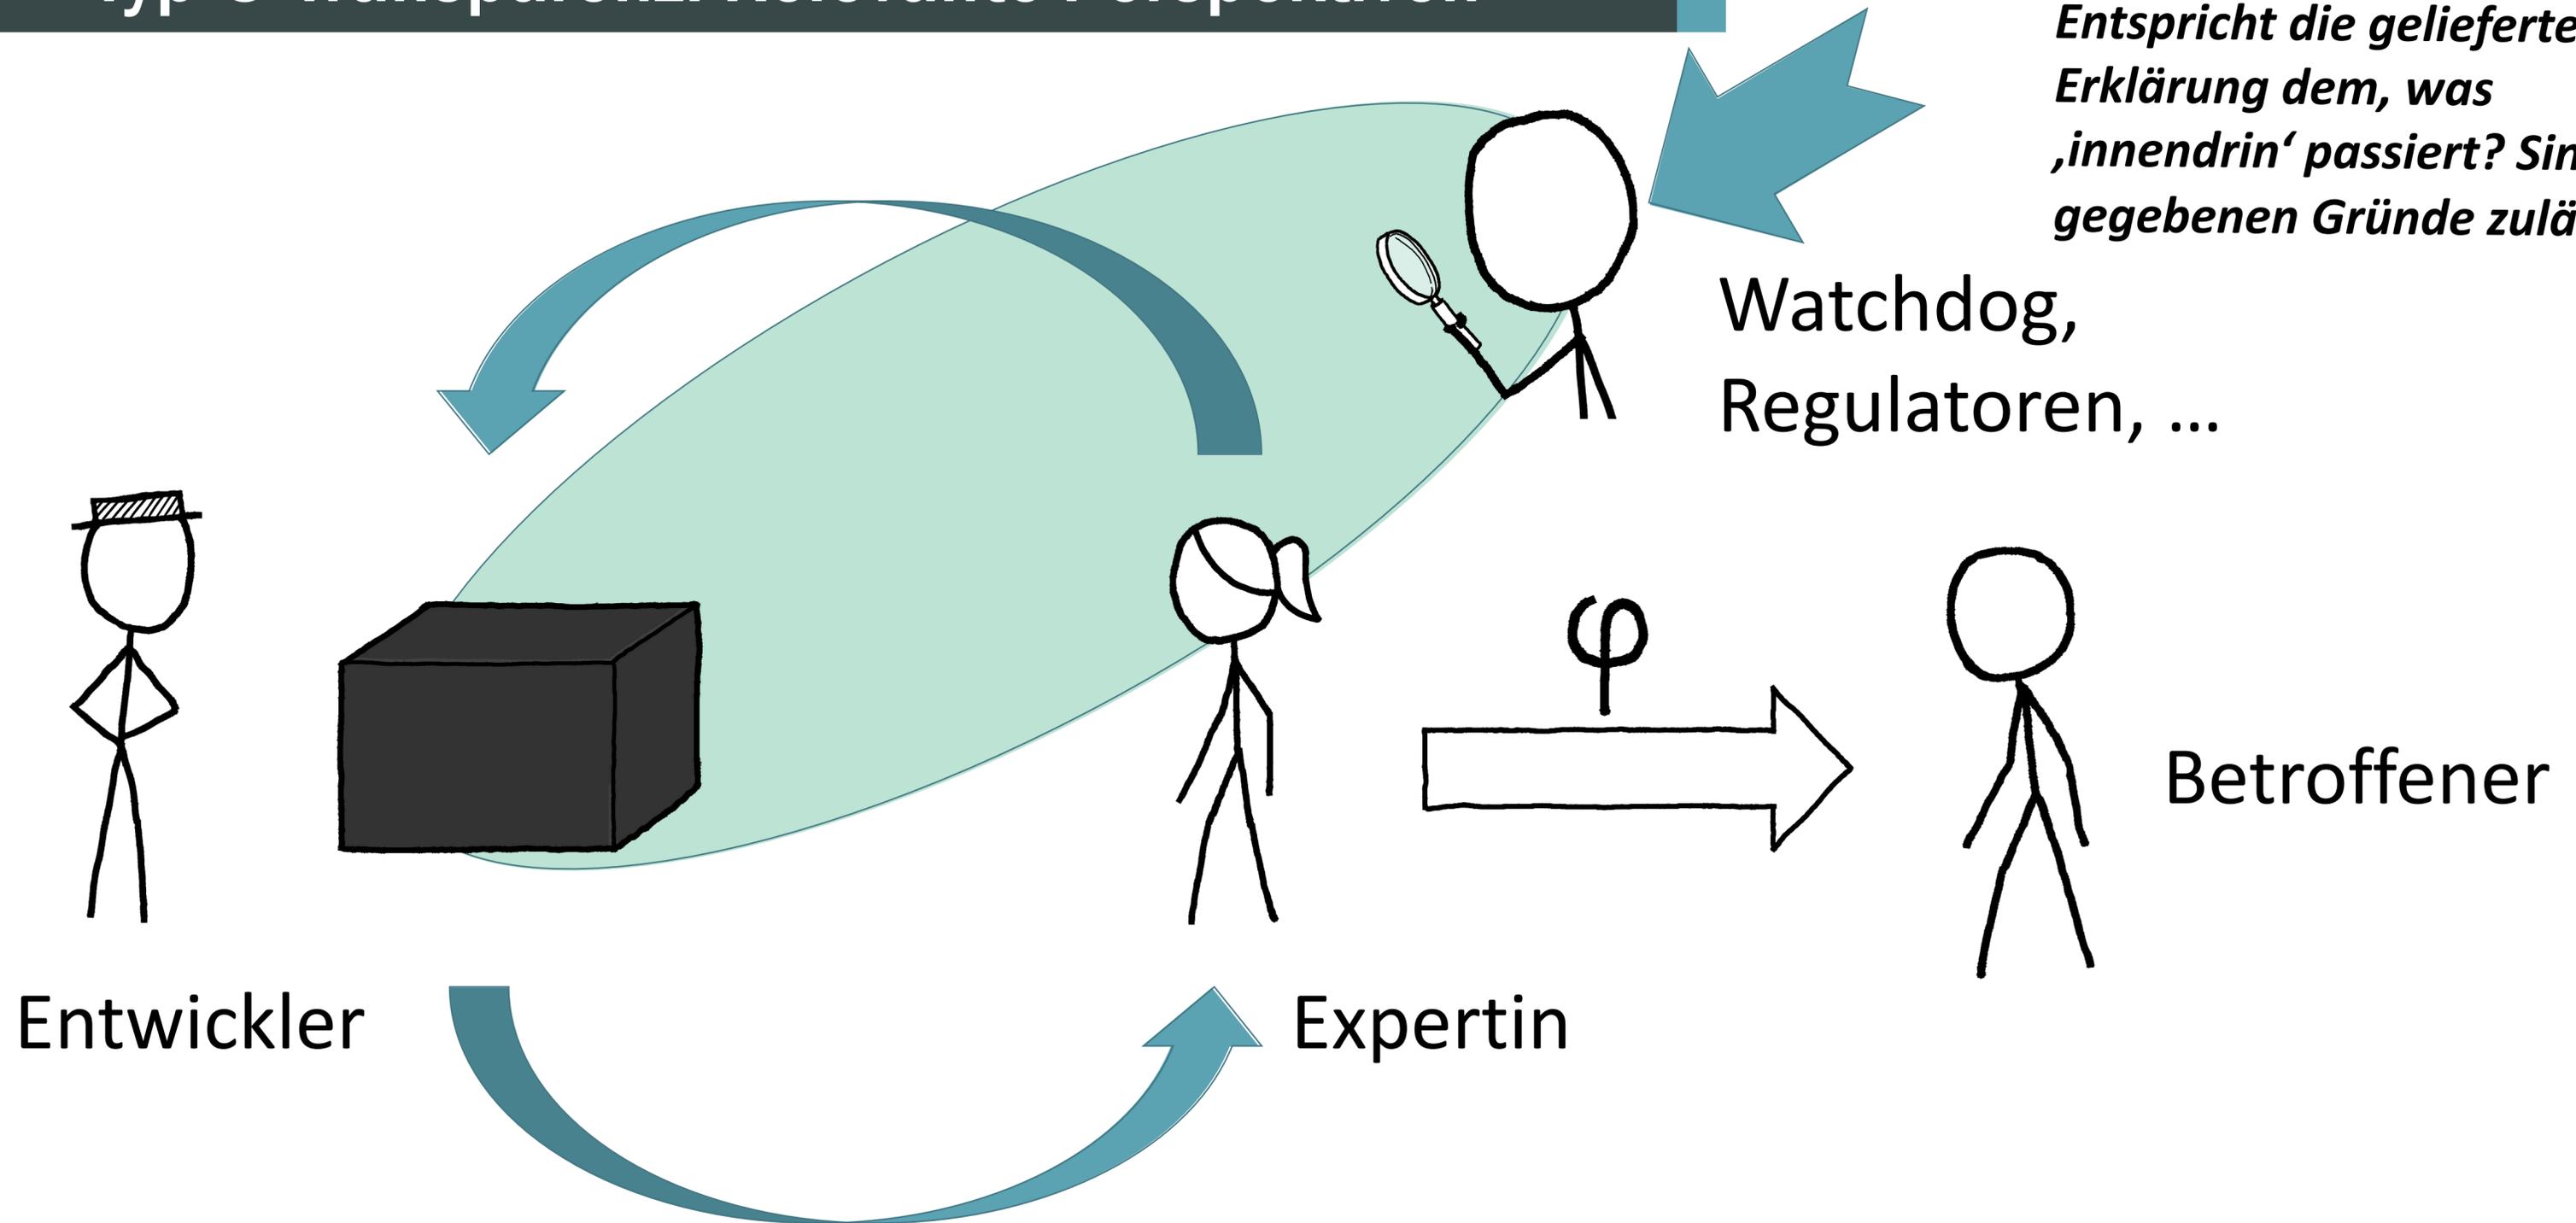


Typ-3-Transparenz: Relevante Perspektiven



Typ-3-Transparenz: Relevante Perspektiven

*Im Zweifelsfall & Transparenz vom Typ 2 vorausgesetzt:
Entspricht die gelieferte Erklärung dem, was
,innendrin' passiert? Sind die
gegebenen Gründe zulässig?*





Typ 3:

Transparenz des Entscheidungsprozesses & Zugang/Zugriff auf den internen, deliberativen Prozess

Umsetzbarkeit?

- Theoretisch u.U. sehr anspruchsvoll bis unmöglich (*Machine-Learning*)
- Viele begriffliche und empirische Fragen sind zu klären.
- Wahrscheinlich sind auch rechtliche Anpassungen nötig.



Typ 3:

Transparenz des Entscheidungsprozesses & Zugang/Zugriff auf den internen, deliberativen Prozess

Warum wichtig?

- Voraussetzung für *angemessene Reflektion des Experten* und damit für verantwortungsvolle Entscheidungen und angemessenen Umgang mit Urteilen
- Womöglich eine Voraussetzung für hinreichend *gerechte* Gesamtsysteme
- Voraussetzungen für *Einzelfallprüfung* (u.a. False Positives/Negatives erkennen)
- Rechtliche Anforderungen: Nicht bloß statistische Aussagen nötig.

Wie können wir Erklärbarkeit ermöglichen und gewährleisten?

Wir wissen es *noch* nicht ...
... aber wir arbeiten an der UdS dran!



Aktuelles
Uni-Porträt
Fakultäten | Einrichtungen
Wirtschaftsportal

Montag, 26. November 2018

Neuer Sonderforschungsbereich: Softwaresysteme sollen ihr Verhalten selbst erklären

Selbst Experten verstehen das Verhalten komplexer Softwaresysteme immer weniger. Dabei regeln diese inzwischen immer stärker unseren Alltag, sei es als intelligente Haussteuerung, im autonomen Fahrzeug oder in der industriellen Produktion. Wissenschaftler der Universität des Saarlandes, zweier Max-Planck-Institute und der Technischen Universität Dresden wollen jetzt in einem neuen Sonderforschungsbereich Mechanismen entwickeln, die nicht nur Experten, sondern auch Laien das Verhalten komplexer Softwaresysteme besser vermittelt. Die Deutsche Forschungsgemeinschaft fördert dieses Großprojekt mit elf Millionen Euro über vier Jahre hinweg.

Kevin Baum

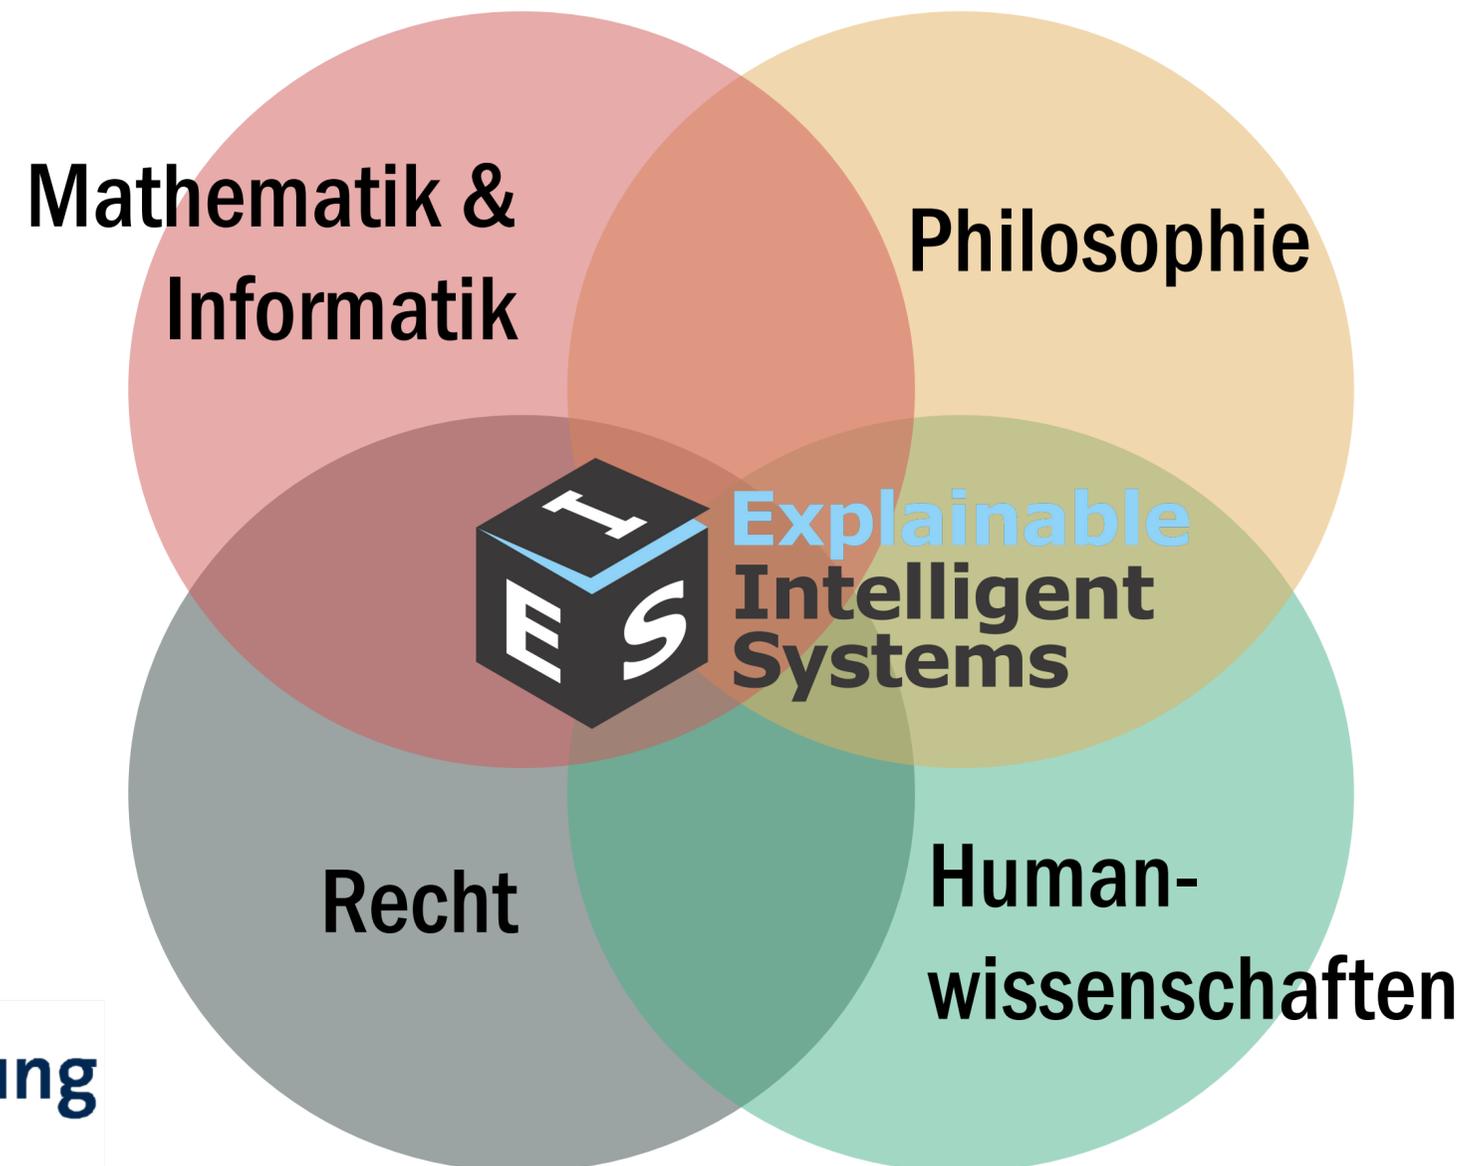
FOUNDATIONS OF PERSPICUOUS SOFTWARE SYSTEMS

— Enabling Comprehension in a Cyber-Physical World —



Weshalb wir KI verstehen können müssen.

Erklärbare Künstliche Intelligenz (KI) = **Ex**plainable **AI** = XAI



Transparenz: Mindestens drei Bedeutungen

Typ 1

~ Wissen, dass ein System über mich urteilt und auf Basis welcher Daten und was mit diesen geschieht



Typ 2

~ Grobes Verstehen und formal nachvollziehbar machen



Typ 3

~ Nachvollziehbarkeit der individuellen Beurteilungen für Experten und Betroffene



Welche Methode für welche Aufgabe?

- Viele Eigenschaften der Methoden zur Erklärungsgenerierung:
 - Ausdrucksstärke
 - Algorithmische Komplexität...
- Viele Eigenschaften von Erklärungen:
 - Genauigkeit
 - Stabilität
 - Verständlichkeit...

Welche Methode für welche Aufgabe?

- **Welche Erklärungsmethode für welche Aufgabe/welchen Aspekt?**
- **Wer definiert Anforderungen** und wer **überprüft**, ob sie erfüllt sind, und **wie?**
- **Ziel** muss sein, die **Ansprüche**, die ein **Bürger** hat/haben soll, möglichst **klar** zu **formulieren**.
Was soll der Effekt sein, was soll jemand damit tun können?
- Dann braucht es begleitende **Studien** (und ggf. neue Entwicklungen), um **herauszufinden, was welche Methode leisten kann**.

Danke für Ihre Aufmerksamkeit!