

hierdurch die Spezifität der laboreigenen Erzeugungslogik von Erkenntnis verloren gehen.³

5 Mathematisierung des Labors und Laborisierung von Gesellschaft

Neben der Ausweitung des Laborbegriffs lässt sich auch eine generelle Transformation des Labors hin zu einem mathematisierten Labor konstatieren: Daten sammeln, auswerten und simulieren, für die Entscheidungen von heute und das Regieren, im biopolitischen Sinne ließe sich hier auch von Verwalten sprechen, der Datenkörper von morgen. Um die bereits weiter oben angeführte umfangreiche Datenflut in den Neurowissenschaften einzuhegen, braucht es allgemeingültige, universell verfasste Algorithmen, die in die Modellierungen und Simulationen einfließen und Bedeutung generieren können. Die Datenflut in fast allen Disziplinen verlangt nach Statistiker*innen und Datenwissenschaftler*innen, die sich der Aufgabe widmen, nach solcherart informatischen und mathematischen Lösungen zu suchen, die auch auf ähnliche Probleme eine Antwort liefern. Daten erheben, sammeln, verwalten, analysieren und interpretieren hat eine enorme Bedeutung in den Laborwissenschaften erlangt. Der Computer mit seiner Möglichkeit, Simulationen durchzuführen, hat das Experimentallabor zu einem ›Dry Lab‹ werden lassen (Merz 2006).

Dry lab oder auch digital laboratory frequently become associated with computer simulation be it in popular accounts or in the discourse of practitioners. The notions seem to suggest that computers and simulation applications constitute research environments in their own right, allowing one to perform computer experiments and endowing one with the potential to replace traditional laboratory settings. (Ebd., 155)

Der Laborraum ist demnach dabei, aus dem Wet Lab herausgelöst und in Standardbüro Räume verlegt zu werden, die sich vor allem durch eine Samm-

3 Sicherlich wäre es interessant, sich diesen geänderten und ausgedehnten Laborbegriff unter der Frage anzuschauen, warum gerade der in den Naturwissenschaften verbreitete Ort der Wissensproduktion hier aufgerufen wird und welche Auswirkungen diese Anrufung des Labors auf die Konnotation andere Formen von Erkenntnisproduktion und -praktiken hat.

lung leistungsstarker Computer auszeichnen. Das führt zu einer veränderten epistemologischen Grundvoraussetzung, zu einer ›bevorstehenden Umwandlung der Neurowissenschaften in eine Ingenieursdisziplin‹ (vgl. Bruder 2017, 119), indem Gehirne und Körper als zusammengesetzte Netzwerksysteme imaginiert werden. Das stimmt besonders für die Computational Neurosciences und die Neuroinformatik, in denen computergestützte Erkenntnistheorien eine bedeutsame Rolle spielen: »Indeed, methodologists in neuroscience have typically worked on various modeling efforts in distinct fields, which means that they tend to think about the systems to be modeled in rather general terms.« (Ebd., 118) Mathematik ist ein bedeutsames Werkzeug in den Computational Neurosciences, aber so wie vormals der Computer als Vorbild für Neuronale Netzwerke ausgedient hatte und heute das Gehirn als Ideal für künstliche neuronale Netze gilt, kann diese Übertragung auch auf das Verhältnis von Mathematik und Neurosciences angewandt werden:

[A] similar argument can be applied to the relationship between mathematics and neuroscience where it is clear that we either are not using the right mathematical tools to understand the brain or such tools have not yet been discovered. The resultant mathematical descriptions should make non-trivial predictions about the system that can then be verified experimentally. This approach takes advantage and has the potential to use the vast amounts of qualitative data in neuroscience and to put it in a quantitative context. (Silvia 2011, 2, zit. n. Bruder 2017, 119)

5.1 Das mathematische Labor: Computerbeweis, Computermodelle und Simulationen

In die Erkenntnisproduktion und Experimentalanordnungen moderner Labore schreiben sich vermehrt Mathematische Logiken und Praktiken ein, unter anderem die Logik des mathematischen Beweisens. Der Beweis stellt, wie bereits in Kapitel 1 ausführlicher beschrieben, den ›Goldstandard‹ der Mathematik dar, neben den formalisierten Axiomen ist es der Beweis, der der Mathematik die Deutungshoheit ermöglicht und sie zu einer objektiven, verallgemeinerbaren Disziplin macht. Der mathematische Beweis ist originär nicht im Labor verortet. Beweise werden gänzlich losgelöst von konkreten Experimenten oder Anwendungen erlangt, einzig das sorgfältige und schrittweise Ableiten aus anderen, bereits bewiesenen Axiomen oder Sätzen wird als regelkonformer Beweis anerkannt. Dennoch existieren verschiedene Versionen des

mathematischen Beweisens, und die Auseinandersetzungen darüber, wie ein guter, richtiger Beweis auszusehen hat, gehen weit in die Geschichte zurück. In den letzten Jahren hat sich durch die Verwendung von Computern eine bestimmte Form des Beweises durchgesetzt, die, so zumindest die Einschätzung Ian Hacking's, wiederum in der Tradition von Leibniz steht. Für Leibniz ist der mathematische Beweis eine notwendige, aber langwierige und wenig kreative Tätigkeit, für deren Erledigung er Rechenmaschinen ins Feld führt, die diese Tätigkeit in Zukunft übernehmen sollen. Leibniz' nur in Gedanken existierende Rechenmaschinen sind heute Realität geworden, der Computer wird inzwischen fast ausschließlich für die Durchführung mathematischer Beweise im Sinne Leibniz' eingesetzt. Mitte des zwanzigsten Jahrhunderts erfuhr der mathematische Beweis eine Neuausrichtung: »The conception of proof as conferring certainty, [...] has changed, in part due to developments in mathematics itself. Proofs have, to put it crudely, become longer and longer, so that it is not possible for a single human to grasp them in their entirety.« (Hacking 2014, 63)

Der mit dem Computer durchgeführte Beweis steht für mehr als nur eine regelkonform durchgeführte Beweisführung, er steht auch für Sicherheit und eine ›höhere‹ Gewissheit, die durch die Exklusion subjektiven und möglicherweise fehlerhaften Eingreifens vonseiten der Wissenschaftler*innen vermeintlich garantiert wird. Dieser Umstand wird in der Mathematik nach wie vor viel diskutiert, denn nicht alle sehen die Mathematik als rein formalistische Angelegenheit, sondern verweisen auch auf kreative Prozesse und erfahrungsbasiertes Wissen, das in die Beweisführung und das Finden neuer Theoreme miteinfließen muss. »Computerbeweise hingegen können nicht wirklich kreativ sein, die finden keine Theoreme – keine neuen.« (Interview 5, 38 Min.) Gleichzeitig hat durch die massive Anwendung von Computermodellen und Simulationen eine Verschiebung im Verständnis des Beweisens stattgefunden.

Durch den vermehrten Einsatz von Computermodellen und Simulationen sollen Theorien, Konzepte und konkrete Prozesse und Funktionsweisen ›bewiesen‹ werden. Diese folgen selbstverständlich nicht den Ansprüchen des eigentlichen mathematischen Beweises, aber Mathematik wird hier eingesetzt, um organische Abläufe zu gestalten, nachzuweisen und letztlich eine zunächst in der Theorie durchgespielte Idee durch die Modellierung und Simulation zu beweisen. So entsteht eine ganz neuen mathematischen Grundprinzipien folgende Erzeugungslogik und bringt das *Mathematische Labor* (Bruder 2017) hervor.

Durch die Verwendung von auf stochastischen Berechnungen basierenden Computermodellen und Simulationen haben sich die Bedingungen der experimentellen Erkenntnisproduktion grundlegend verändert. Daten werden nicht länger aus deduktiven Experimentalanordnungen hervorgebracht, sondern folgen der induktiven Logik. Allein die Entscheidung, auf welchen Wahrscheinlichkeitsbegriff in den Berechnungen zurückgegriffen wird, bleibt der Wahl der Wissenschaftler*innen überlassen. Die Wahrscheinlichkeitstheorie implementiert in jeden Entscheidungsschritt stochastische Kalkulationen und führt zu einer ganz spezifischen Ausgestaltung des mathematischen Beweises, der sich allein durch die omnipräsente und selbstverständliche Anwendung als mathematische Beweislogik durchgesetzt hat. Die Stochastik als Verknüpfung von Statistik und Wahrscheinlichkeit folgt der Vorgehensweise der induktiven Logik, die nicht nach »wahren«, allgemeingültigen Aussagen sucht, sondern sich mit statistisch validen Angaben zufriedengibt.

Something entirely new has been added to the tools of the physicist, indeed of all scientists and quite a few humanists. In the sciences we have powerful and increasingly fast computational techniques to make approximate solutions to complex equations that cannot be solved exactly. They enable practitioners to construct simulations that establish intimate relations between theory and experiment. Today, much – maybe most – experimental work in physics and chemistry is run alongside, and often replaced by, simulations. (Hacking 2014, 50)

Computermodelle und Simulationen sind beides für sich genommen voraussetzungsreiche Werkzeuge, auf die Funktion von Computermodellen bin ich in Kapitel 2 näher eingegangen. Simulationen werde ich im Folgenden kurz beschreiben. Dudai und Evers formulieren es so: »The term »simulation« can acquire different meanings in different contexts. Here we will restrict our treatment to simulation in science and engineering. In these disciplines, simulation involves mathematical and engineering methods.« (2014, 254) Simulationen nehmen verschiedene Rollen im erkenntnisgenerierenden Prozess ein. Eine pragmatische Systematik, um die verschiedenen Funktionen von Simulationen in der Wissenschaft und Technik einzuordnen, basiert auf zwei Hauptkriterien – dem Ziel, das mithilfe einer Simulation erreicht werden soll, und dem Träger, dem Medium, in dem die Simulation umgesetzt wird (vgl. ebd.). Bei den Zielen einer Simulation wird zunächst zwischen vollständigen Simulationen eines ganzen Systems und der Simulation partieller Teil-

bereiche unterschieden. Ebenso gehören zu den Zielen einer Simulation: das funktionelle Nachbauen und das theoretische Verstehen eines Systems und der Prozesse, um ein Konzept zu beweisen oder ihre operative Leistungsfähigkeit zu prüfen, Kosten und Risiken zu minimieren, das System zu manipulieren oder die Funktionen zu vervielfältigen. Zum Medium beziehungsweise dem Mittel, eine Simulation durchzuführen, gehören entweder ein natürlicher Träger oder rein artifizielle Träger wie mittels mathematischer Modelle im Computer. Simulationen können also konkret oder abstrakt durchgeführt werden, können Daten-getrieben oder Modell-getrieben sein, können in verändertem Maßstab oder maßstabsgetreu nachgebaut werden (vgl. ebd.).

Computational Neurosciences können als Kombination aus Experimentallabor und mathematischem Labor beschrieben werden. Die Disziplin setzt sich einerseits zusammen aus den numerischen Größen, wie etwa Membrandurchlässigkeit und Ionenfluss, die durch elektrophysiologische Ableitungen an Synapsen und Neuronenverbindungen ermittelt wurden. Diese Werte sind bereits vor vielen Jahren in die Berechnungsmodelle von Neuronentätigkeit wie das Hodgkin-Huxley-Modell eingeflossen und wurden in den letzten Jahren nur noch graduell angepasst. Andererseits können mit den so entstandenen Modellen heute die abgeleiteten neuronalen Feuerungsratendaten (meist aus Tierversuchen) modelliert und berechnet werden. Gleichzeitig werden diese Berechnungen eingesetzt, um mithilfe von theoretischen Überlegungen (wie der effizienten Komplexitätstheorie; siehe Kap. 3) und Simulationen die Modelle entsprechend ihrer Durchführbarkeit zu verbessern oder zu falsifizieren. Der Fokus der Computational Neurosciences liegt eher auf der Entwicklung immer besser angepasster Computermodelle, mit denen man neuronale Aktivität und Vernetzungsmuster berechnen und simulieren kann, weniger darauf, Daten auszuwerten. Welche Überlegungen zur Verbesserung der Modellperformances herangezogen werden, zeigen die Laborstudien rund um das Blue-Brain-Projekt der Wissenschaftssoziologin Tara Mahfoud und des Filmemachers Noah Hutton. Beide verweisen auf projektinterne Diskussionen rund um Frage, wie die Ähnlichkeit (beziehungsweise Unähnlichkeit) zwischen den eigenen synthetisierten, durch Algorithmen erzeugten Zellen und den rekonstruierten Zellen aus dem elektrophysiologischen Labor zu bewerten sei. War es wichtiger, dass die synthetisierten Neuronen aussahen, wie andere Neuronen aussehen, oder war es wichtiger, eine hohe Anzahl von Merkmalen zu haben, die mit den rekonstruierten Zellen übereinstimmten, auch wenn sie nicht ähnlich aussahen? Schnell fokussierte man sich in der Diskussion auf statistische Tests,

die zur Erzeugung von Variabilität erforderlich sind, auch wenn nicht alle Zellen gleich aussehen:

One of the problems that was highlighted was that when Henry evaluated some of the synthesised cells, he would say they didn't »look nice« and that more features should be added. Adding features, Nancy said, made running statistical analyses for similarity more complicated. Biologists, she said, want to include everything in the model, but that compromised the performance of the model. (Mahfoud 2018, 147f.)

Hier schließt sich die Problematik an, die richtige Menge an Merkmalen in ein Modell aufzunehmen, um möglichst realitätsgetreu zu modellieren, aber gleichzeitig zweckmäßig zu entscheiden, um nicht die Leistung des Modells zu schwächen. Die Entscheidungen über die im Modell und den Simulationen verwendeten Werte und Merkmale sind ausschlaggebend für den Output und die Erkenntnisse, die aus den Probeläufen entstehen. Diese Entscheidungen werden subjektiv am Computer vorgenommen, von in *Denkstile* (Fleck 1980) bestimmter *Denkkollektive* (ebd.) eingebundenen Individuen, sind aber entscheidend für den Erfolg eines Modells beziehungsweise einer Simulation. Das Beispiel aus Henry Makrams *Blue Brain* Labor über die Frage der angemessenen Zugabe an Zufall und Variabilität in Computermodellen zeigt eindrücklich, wie viel Subjektivität in der Praxis mathematischer Labore steckt.

Asked how she approached the extraction of morphological constants from the highly variable shapes of neurons found in the cortex, Kanari explained that she uses »the features that are consistent, and exploits them [...] so [we] generate structures that have the same main topology, but also add some noise. Add the variability that you see in biology.« I then asked: »How do you add the right kind of variability?« To which she replied: »That's a good question, because the right kind, we can never know what's the right kind of variability.« (Hutton 2022 [in Druck])

5.2 Laborisierung von Gesellschaft

In ihrem Buch *Automated Inequality* gibt Eubanks (2015) ein Beispiel für die Auswirkungen eines trainierten Algorithmus, der bei einer großen US-amerikanischen Krankenversicherung darüber entscheidet, ob und zu welchen Konditionen Menschen versichert werden. Künstliche Intelligenzen erwecken den Anschein, neutral zu sein, da sie in der Anwendung vermeintlich von

menschlichen Unzulänglichkeiten befreit sind. Wie fatal diese Unterschätzung von algorithmisch gelenkten Entscheidungsprozessen ist, darüber klärt Eubanks in ihrem Buch auf:

But that's the thing of being targeted by an algorithm: you get a sense of a pattern in the digital noise, an electronic eye turned toward you, but you can't put your finger on exactly what's amiss. There is no requirement that you be notified when you are red-flagged. With the notable exception of credit reporting, we have remarkably limited access to the equations, algorithms, and models that shape our life chances. (2015, 5)

Ein gut trainierter Algorithmus vergisst nicht – und kann auf alle jemals eingespeisten Informationen zurückgreifen. Eben dieses Versprechen birgt gleichzeitig Gefahren. Mit der Automatisierung statistischer Berechnungen und darüber vorgenommenen Bewertungen findet eine unsichtbare Weiterführung laborativer Praktiken statt in Bereichen, die eher politische und/oder soziale Antworten benötigen. Die in die Bewertungssysteme eingespeisten Daten können nicht »vergessen« werden und die Systeme reproduzieren so einprogrammierte Biases, können dabei aber zwischen Kausalität und Korrelationen nicht unterscheiden. Diese Argumentationsweisen haben Einfluss auf Subjekte außerhalb des Labors. Im Anschluss an Teresa de Lauretis' (1987) Ansatz, Geschlecht als Ensemble von Auswirkungen zu konzeptualisieren, »die in den Körpern, den Verhaltensweisen, den gesellschaftlichen Beziehungen durch das Dispositiv einer komplexen politischen Technologie herbeigeführt werden« (Döring/Fitsch 2016, 62), will Ruha Benjamin (2019) auch Race als Effekt und Produkt verschiedener Technologien verstanden wissen. »Race as Technology: This field guide explores [...] how race itself is a kind of technology – one designed to separate, stratify, and sanctify the many forms of injustice experienced by members of racialized groups.« (36) Mit *Laboralisierung der Gesellschaft* sind diese auf Mathematik und Statistik begründeten Regulierungstechnologien aus dem Labor gemeint. Beruhend auf einer generellen Mathematisierung der Wahrnehmung und Kanalisierung durch Berechnungsschritte von Computern, egal welcher Größe, tragen sie die erkenntnistheoretischen Bedingungen laborativer Wissensproduktion in die Mitte der Gesellschaft.

Das Wissen der Computermodelle und Simulationen folgt der Mathematischen Logik und unterliegt einer »Algorithmizität, das heißt, sie ist geprägt durch automatisierte Entscheidungsverfahren, die den Informationsüberfluss reduzieren und formen, so dass sich aus den von Maschinen produ-

zierten Datenmengen Informationen gewinnen lassen, [...] und zu Grundlagen des singulären und gemeinschaftlichen Handelns werden können« (Stalder 2017, 13). Um diese riesigen, täglich produzierten Datenmengen auszuwerten, braucht es Algorithmen, deren Verständnis von großer Wichtigkeit ist, sind sie es doch, die etwas in den Daten sichtbar machen und etwas zu sehen geben, dessen Interpretation darüber bestimmt, welche Bedeutung den Daten beigemessen wird.

Der Einsatz digitaler Technologien in der Wissensproduktion bedeutet für die neurowissenschaftliche Forschung zweierlei: Zum einen nimmt sie Einfluss auf das Sammeln, die Nutzung und die Weiterverarbeitung der gesammelten Daten und führt durch die globale Vernetzung von Daten zu einer Automatisierung datengetriebener statistischer Erkenntnisproduktion und zu Big Data. Zum anderen bestimmen Digitalität und Virtualität nicht nur die Art und Weise, wie Wissen hergestellt wird, sondern auch das epistemische, also erkenntnistheoretische Grundgerüst, mit dem auf Prozesse im Gehirn geschaut wird und wie diese Prozesse modelliert werden. Die durch die Digitalisierung beobachtbaren methodischen Anpassungen in den neurowissenschaftlichen Disziplinen brachten Effekte für das jeweilige epistemische Verständnis mit sich. Diese Entwicklungen spitzen sich derzeit auf zwei Ebenen zu: zum einen in den von Deep-Learning-Algorithmen hervorgebrachten Entscheidungen künstlicher Intelligenzen, die es verunmöglichen, nachzuvollziehen, wie sie zum jeweiligen Ergebnis gekommen sind. Zum anderen breitet sich die Logik des Engineerings und des Verschaltens in seiner informatischen Bedeutung so gut wie in allen auf Computer gestützten Disziplinen immer weiter aus: »Regulation by Engineering: The Pretense of the New in the Eternal Same« (Fitsch et al. 2020, 53). Dabei vermischen sich in diesem Engineeringansatz zwei sehr unterschiedliche Ebenen:

At the bottom, one has to realize that these various activities, though superficially similar, are of a radically different kind. Constructing a machine that works (such as a highly parallel computer) is an engineering problem. [...] Understanding the brain, on the other hand, is a scientific problem. The brain is given to us, the product of a long evolution. (Crick 1989, 132)

Damit nähert sich die Modellbildung in den Natur- und Technikwissenschaften ihren derzeitigen technischen Möglichkeiten an: Schnellere Rechner können ein Vielfaches an Daten technisch so konstruieren, um sie zu berechnen, und erzeugen damit die Illusion von Echtzeitverarbeitung, von Denken und vermeintlich freien Entscheidungen. Somit verwundert es auch nicht, dass

heute das Gehirn mit seinen komplexen Abläufen in den neuronalen Netzwerken und Verschaltungen dem Computer als Vorbild dient.

Nicht nur der Erkenntnisprozess transformiert sich, auch das, was wir als Wissen und als glaubwürdige Beschreibung der Welt anerkennen, ändert sich durch die digitalen, mathematischen wissenschaftlichen Bezugnahmen. Es kommt zu einer weit reichenden Neufassung des Wissensbegriffs, für dessen Verständnis zwischen Daten, Informationen, Kommunikation und Wissen unterschieden werden muss, um diese in Relation zu ihrer technischen Verfasstheit und Reproduzierbarkeit neu zu bestimmen:

Die Produktion von Daten als allgemeinster Rohstoff für Wissen benötigt Techniken der Beobachtung; die Produktion von Informationen als bewertete Daten braucht Techniken der Selektion und Evaluation, der Bildung von Präferenzen und Prioritäten; und die Produktion von Wissen, Wissen verstanden als der Einbau von Informationen in Erfahrungskontexte, verlangt Techniken und Technologien der Steuerung von Erfahrung. (Willke 2005, 129)

Die Technisierung von Wissen und deren Kommunikation muss in der Abhängigkeit dieses Wissens von mathematisierten Wahrnehmungstechnologien verstanden werden. Über diesen Aspekt hinaus basiert digitales Wissen nicht nur auf seiner technischen Reproduzierbarkeit, sondern auch auf der binär-methodischen Herstellungslogik; also nicht nur das Wissen, sondern die *Wahrnehmung* selbst wird *mathematisiert*. Durch die *Mathematisierung von Wahrnehmung* werden Entscheidungen an Apparaturen abgetreten, die mit einer Vielzahl an Trainingsdaten, Mustern, Häufigkeiten und Rankings gefüttert wurden, sodass sie über einen vermeintlichen Erfahrungsschatz verfügen, der weit über den eines einzelnen Menschen hinausgeht. Das nächste Kapitel beschreibt diese technisch induzierte Automatisierung als Mathematisierung von Wahrnehmung, also den mathematischen Grundbedingungen aktueller Erkenntnispraktiken.

Knorr-Cetina hat in ihren Arbeiten auf den erzeugungslogischen Moment des Labors verwiesen: Objekte werden hier nicht beschrieben, sondern erzeugt und hervorgebracht. Das mathematische Labor, an Mathematik und Visualisierungen geknüpfte Immutable Mobiles, ist kein beschreibendes, sondern ein Rahmenbedingungen erzeugendes Labor, das Vorhersagen und Entscheidungen vornimmt. Die stochastischen Berechnungsweisen und selbstlernenden Algorithmen erzeugen formal-mathematische Vorhersagen, die direkten Einfluss auf die gesellschaftlichen Lebensbedingungen haben. Die For-

schung ist Daten-getrieben, das heißt, ihr Ausgangspunkt sind nicht Hypothesen oder eine spezifische Fragestellung, anhand derer sie ein Studiendesign oder ein Modell bilden. Das Fundament bilden gesammelte Daten, die dann nach Mustern und Korrelationen abgesucht werden, die Interpretation der Daten erfolgt unabhängig ihrer kontextspezifischen Rahmenbedingungen. Dabei wird das Wissen in die Zukunft gerichtet und »die erwartete[n] Möglichkeiten in erfahrbare Wirklichkeiten transformier[t]« (Dickel 2019, 9). Eine *Laborisierung der Gesellschaft* verlagert das laborative Datensammeln und -interpretieren in gesellschaftliche Praktiken. Eine labortypische Erkenntnisproduktion kann in Echtzeit und an vielen Orten gleichzeitig durchgeführt werden, wir alle liefern die benötigten Daten. »Die Produktion und Rezeption [erkenntnistheoretischer] Artefakte verwandelt sich dabei von einer exklusiven Expertentätigkeit zu einer öffentlichen sozialen Praxis.« (Dickel 2019, U4)

6 Die fehlende halbe Sekunde und die Rückkehr des Körpers unter den Vorzeichen des Labors

Die *Laborisierung der Gesellschaft* verlangt wiederum, dass die vormalis von allem Subjektiven und Körperlichen bereinigten und durch formalisierte Symbole, Repräsentationen und Immutable Mobiles ersetzten Wissensprozesse, die Körper, Organismen und Prozesse, wieder eingeholt werden. Allerdings in einer handhabbaren Form und gemäß bereits erfolgter Reduktionen und in Technologien geflossener Vorstellungen von zum Beispiel organischen neuronalen Netzwerken und ihren Prozessen. Am Beispiel der ›fehlenden halben Sekunde‹, die in verschiedenen physiologischen Studien in den 1970er-Jahren entdeckt wurde (Libet 2005), lässt sich zeigen, wie der Körper in das hochtechnisierte und formalisierte Wissen wieder integriert werden soll und welchen Stellenwert das Unverfügbare darin bekommt. Die Anrufung situierter Körperlichkeit muss hier unter zwei Prämissen verstanden werden: Erstens wurde der Körper aus der Erkenntnisproduktion sukzessive hinausgedrängt, unterstützt durch die Kontinuität laborativer Praxen, die die Erkenntnisproduktion schrittweise von der Körperlichkeit und Kontextgebundenheit der Untersuchungsgegenstände durch die Übertragung ins Labor gelöst haben. Zweitens wurde das erkenntnisgenerierende Subjekt im Labor durch die technischen, formal-mathematischen Methoden ersetzt und bleibt so im Erkenntnisprozess selbst körperlos. Die Entdeckung der fehlenden halben Sekunde