

Seminar Kognitive Neurowissenschaften

Probabilistische Modelle der
Informationsverarbeitung im Gehirn

Dr. Sebastian Bitzer

Sebastian Bitzer

- BSc, Cognitive Science, Osnabrück, 2004
- MSc, Intelligent Systems, London, 2006
- PhD, Machine Learning for Robotics, Edinburgh, 2010
- Postdoc, MPI CBS, Leipzig, 2010-2015
- wiss. Mitarbeiter, Professur für Neuroimaging, TUD, seit 01.04.2015

Heute

1. Inhalt des Seminars
2. Ablauf im Juli

Lernziele

- Grundlagen probabilistischer Modellierung verstehen
- typische Anwendungsgebiete anhand von Beispielen erarbeiten
- einschätzen können wann Modell Sinn macht und praktikabel ist

Was ist ein Modell?

Ein **mathematisches Modell** ist ein mittels mathematischer Notation erzeugtes Modell zur Beschreibung eines Ausschnittes der beobachtbaren Welt. Dieses Modell kann in beliebigen, begrenzten Bereichen der beobachtbaren Realität, wie z. B. den Naturwissenschaften, den Wirtschafts- oder Sozialwissenschaften, der Medizin oder den Ingenieurwissenschaften Anwendung finden. Mathematische Modelle erlauben eine logische, strukturelle Durchdringung je nach Art hinsichtlich von geltenden Gesetzmäßigkeiten, erlaubten und nicht erlaubten Zuständen, sowie seiner Dynamik mit dem Ziel, diese Erkenntnisse auf das modellierte System zu übertragen.

Der Prozess zur Erstellung eines Modells wird als Modellierung bezeichnet. Die Erstellung eines mathematischen Modells für einen Realitätsausschnitt ist nicht mehr Aufgabe der Mathematik, sondern des jeweiligen Wissenschaftsgebietes. Inwieweit ein mathematisches Modell Vorgänge in der Realität korrekt beschreibt, muss durch Messungen überprüft und validiert werden.

Das Gehirn als Computer

Recent models in modern neuroscience treat the brain as a biological computer, very different in mechanism from an electronic computer, but similar in the sense that it acquires **information** from the surrounding world, stores it, and processes it in a variety of ways, analogous to the central processing unit (CPU) in a computer.

<http://en.wikipedia.org/w/index.php?title=Brain&oldid=658826658>

Information

Informationstheorie (Shannon):

definiert Information abhängig von der Wahrscheinlichkeit einer Hypothese

z.B.:

Hyp = 'Draußen regnet es.'

A: $p(\text{Hyp}) = 0.5$ (Du hast keine Ahnung)

B: $p(\text{Hyp}) = 0.1$ (Wetterbericht gelesen,
Sonne schien vorhin)

Information = Entropie = $-p * \log(p) - (1-p)*\log(1-p)$

Entropie(A) = 1 bit

Entropie(B) = 0.47 bit

Informationsverarbeitung ist die Aktualisierung der Wahrscheinlichkeiten von Hypothesen über unsere Umwelt

Bayesian Brain



« Is There Signal in the fMRI Noise?

Is Synesthesia A Brain Disorder? »

Where Are The Big Ideas in Neuroscience? (Part 1)

By Neuroskeptic | April 19, 2015 11:03 am

Possibly the closest thing neuroscience has to a big idea in the psychology sense is the Bayesian Brain, the idea that the brain is built around Bayesian inference. As far as I can see, Karl Friston's Bayesian Free Energy Principle (FEP) is perhaps neuroscience's only candidate for a theory on the scale of Freud's.

<http://blogs.discovermagazine.com/neuroskeptic/2015/04/19/where-big-ideas-neuroscience/>

Organisatorisches

- 4 Termine im Juli:
 - Fr., 03.7., 11-18 Uhr
 - Fr., 10.7., 11-18 Uhr
 - Fr., 17.7., 11-18 Uhr
 - Fr., 24.7., 11-14:30 Uhr
- Ort: Raum FAL 156 (Lehrraumzentrum der Klin. Psychologie im Bürokomplex Falkenbrunnen)

Ablauf

- ein Vortrag pro Team pro Termin
- 1. Termin: von Liste aussuchen
- darauf folgende Termine:
 - neue Vortragsthemen basierend auf in der Diskussion aufgekommene Fragen beim letzten Termin

Ablauf eines Termins

1. Einführung / Wiederholung (ich, 30min)
2. Vorträge: 5x (30min Vortrag + 30min Diskussion)
3. Themenfindung (30min)

Themen zum 1. Termin

1. ich: kurze Einführung / Wiederholung der Regeln der Wahrscheinlichkeitsrechnung
2. Logik mit Wahrscheinlichkeiten: Jaynes, ch. 1
3. gute Modelle: Gelman2011
4. eine erste konkrete Studie: Ernst2002
5. Wahrnehmung und Lernen mit Wahrscheinlichkeiten im Gehirn: Fiser2010
6. Über- und Ausblick probabilistischer Modelle: Pouget2013

Logik erweitert mit Wahrscheinlichkeiten



Edwin Thompson Jaynes
(1922–1998)
physicist
photo taken circa 1960
http://en.wikipedia.org/wiki/Edwin_Thompson_Jaynes

- Jaynes, E. T.; Bretthorst, G. L. (ed.) **Probability Theory: The Logic of Science**. Cambridge University Press, 2003 (only chapter 1)

“The actual science of logic is conversant at present only with things either certain, impossible, or entirely doubtful, none of which (fortunately) we have to reason on. Therefore the true logic for this world is the calculus of Probabilities, which takes account of the magnitude of the probability which is, or ought to be, in a reasonable man’s mind.”

— James Clerk Maxwell (1850)

Wie kann man die Logik sinnvoll erweitern?

Gute Modelle

- Prolog: Asimov, The relativity of wrong.

<http://chem.tufts.edu/answersinscience/relativityofwrong.htm>

- Gelman, A. **Induction and Deduction in Bayesian Data Analysis.** RMM, 2011, 2, 67-78

The classical or frequentist approach to statistics (in which inference is centered on significance testing), is associated with a philosophy in which science is deductive and follows Popper's doctrine of falsification. In contrast, Bayesian inference is commonly associated with inductive reasoning and the idea that a model can be dethroned by a competing model but can never be directly falsified by a significance test. The purpose of this article is to break these associations, which I think are incorrect and have been detrimental to statistical practice, in that they have steered falsificationists away from the very useful tools of Bayesian inference and have discouraged Bayesians from checking the fit of their models. From my experience using and developing Bayesian methods in social and environmental science, I have found model checking and falsification to be central in the modeling process.

Wann ist ein Modell ein gutes Modell?

Eine erste konkrete Studie

- Ernst, M. O. & Banks, M. S. **Humans integrate visual and haptic information in a statistically optimal fashion.** Nature, 2002, 415, 429-433

When a person looks at an object while exploring it with their hand, vision and touch both provide information for estimating the properties of the object. Vision frequently dominates the integrated visual-haptic percept, for example when judging size, shape or position, but in some circumstances the percept is clearly affected by haptics. Here we propose that a general principle, which minimizes variance in the final estimate, determines the degree to which vision or haptics dominates. This principle is realized by using maximum-likelihood estimation to combine the inputs. To investigate cue combination quantitatively, we first measured the variances associated with visual and haptic estimation of height. We then used these measurements to construct a maximum-likelihood integrator. This model behaved very similarly to humans in a visual-haptic task. Thus, the nervous system seems to combine visual and haptic information in a fashion that is similar to a maximum-likelihood integrator. Visual dominance occurs when the variance associated with visual estimation is lower than that associated with haptic estimation.

Mit welchem Mechanismus integriert das Gehirn Informationen verschiedener Sinne?

Wahrscheinlichkeiten im Gehirn?

- Fiser, J.; Berkes, P.; Orbán, G. & Lengyel, M.
Statistically optimal perception and learning: from behavior to neural representations. Trends Cogn Sci, 2010, 14, 119-130

Human perception has recently been characterized as statistical inference based on noisy and ambiguous sensory inputs. Moreover, suitable neural representations of uncertainty have been identified that could underlie such probabilistic computations. In this review, we argue that learning an internal model of the sensory environment is another key aspect of the same statistical inference procedure and thus perception and learning need to be treated jointly. We review evidence for statistically optimal learning in humans and animals, and re-evaluate possible neural representations of uncertainty based on their potential to support statistically optimal learning. We propose that spontaneous activity can have a functional role in such representations leading to a new, sampling-based, framework of how the cortex represents information and uncertainty.

Wie können Wahrnehmung und Lernen in einem Formalismus konsistent beschrieben werden?

Über- und Ausblick

- Pouget, A.; Beck, J. M.; Ma, W. J. & Latham, P. E. **Probabilistic brains: knowns and unknowns.** Nat Neurosci, 2013, 16, 1170 - 1178

There is strong behavioral and physiological evidence that the brain both represents probability distributions and performs probabilistic inference. Computational neuroscientists have started to shed light on how these probabilistic representations and computations might be implemented in neural circuits. One particularly appealing aspect of these theories is their generality: they can be used to model a wide range of tasks, from sensory processing to high-level cognition. To date, however, these theories have only been applied to very simple tasks. Here we discuss the challenges that will emerge as researchers start focusing their efforts on real-life computations, with a focus on probabilistic learning, structural learning and approximate inference.

Welche Art von Experimenten wurde schon probabilistisch modelliert? Was sind offene Fragen?

Organisatorisches 2

- Downloads:
 - Professur für Neuroimaging → teaching → Summer Semester 2015 → probabilistic modelling
- Wahl des 1. Themas bis 08.05.2015:
 - Email an sebastian.bitzer@tu-dresden.de
 - Wunschthema + 2 Alternativen