

EEG-Quellenkarte: ein interaktives Browser-Werkzeug – und wie genau Quellenrekonstruktion wirklich ist

Robert Lüdke · B.A. Philosophie & Sozialwissenschaften, Humboldt-Universität zu Berlin

Werkzeug: dirksen47.space/neuro · gebaut mit MNE-Python, three.js und KI-gestützter Programmierung (Claude Code)

Zusammenfassung. Ich habe eine Web-Anwendung gebaut, die Aktivität auf der Rinde des FreeSurfer-Standardgehirns simuliert, sie über ein Drei-Schalen-Kopfmodell (BEM) auf 128 Elektroden projiziert und die Quellen live im Browser mit vier linearen Inversverfahren zurückrechnet (MNE, dSPM, sLORETA, eLORETA). Um zu quantifizieren, was solche Rekonstruktionen zeigen können, habe ich für alle 5124 Rindenquellen und sechs Elektrodenmontagen (8–128 Kanäle) eine Auflösungsanalyse gerechnet, mit und ohne Kopfmodell-Fehler, dazu eine Monte-Carlo-Simulation mit Messrauschen. Ohne Rauschen lokalisieren sLORETA und eLORETA jede Punktquelle exakt; mit realistischem Rauschen hängt ihre Genauigkeit stark von der Elektrodendichte ab (Median $\approx 0,5$ cm bei 64 Kanälen, $\approx 3,5$ cm bei 8), und eine Verschmierung von ≈ 4 –6 cm bleibt bei allen Verfahren. Weil das inverse Problem unterbestimmt ist, ist jedes Quellenbild zum Teil ein Bild seiner Modellannahmen.

01 Das Werkzeug

Das Vorwärtsmodell folgt der Standard-Pipeline von MNE-Python: Rinde von fsaverage, ein ico4-Quellraum (5124 Dipole senkrecht zur Rinde), ein dreischaliges BEM (Haut, Schädel, Gehirn; 0,33 / 0,0066 / 0,33 S/m) und 128 Elektroden des 10-05-Systems. Die Leadfield-Matrix G (128×5124) steckt komprimiert in der Seite; ein Web Worker berechnet die Inversoperatoren für jede Montage, Methode, Regularisierung und jedes Kopfmodell.

$$\mathbf{b} = \mathbf{G} \mathbf{q} + \mathbf{n}$$

$$\text{MNE: } \mathbf{K} = \mathbf{R} \mathbf{G}^T (\mathbf{G} \mathbf{R} \mathbf{G}^T + \lambda^2 \mathbf{C})^{-1}, \quad \lambda^2 = 1/\text{SNR}^2$$

dSPM normiert die MNE-Schätzung auf ihre Rauschvarianz, sLORETA standardisiert mit der Auflösungsmatrix, eLORETA iteriert Gewichte, so dass Punktquellen ohne Rauschen exakt lokalisiert werden. Zwanzig simulierte Aktivitäten (z. B. Augen zu: okzipitales Alpha; Handbewegung: kontralaterales Mu) erscheinen als Bandleistungskarten auf einer Rinde aus 160 000 Punkten, neben den echten Quellen. Man kann Elektroden an- und abschalten, Rauschen zufügen, Regularisierung und Tiefengewichtung ändern und das EEG mit einem bewusst falschen Kopfmodell erzeugen (Elektroden ≈ 6 mm verschoben, Schädelleitfähigkeit 1/25 statt 1/50, größeres BEM).

02 Mini-Studie: Methode

Für jede Montage und Methode habe ich die Auflösungsmatrix $R = K G$ berechnet (Hauk et al., 2022). Ihre Spalten sind Punktbildfunktionen; daraus folgen der **Lokalisierungsfehler** (Abstand zwischen echter Quelle und Maximum ihrer Rekonstruktion) und die **räumliche Streuung**. Weil die Auflösungsmatrix Rauschen ignoriert, kam eine Monte-Carlo-Simulation hinzu: 400 zufällige Quellen $\times$ 10 Ziehungen weißen Sensorrauschens bei SNR 1, 3 und 10 (Signal-RMS durch Rausch-RMS), mit identischem Rauschen in allen Bedingungen. $\lambda^2 = 1/9$; Tiefengewichtung 0,8 für MNE/dSPM. Der Kopfmodell-Fehler verändert die Leadfield-Matrix um 15 % (relative Frobenius-Norm).

03 Ergebnisse

- **Ohne Rauschen:** sLORETA und eLORETA haben bei jeder Kanalzahl einen Lokalisierungsfehler von null – ihre bekannte theoretische Eigenschaft. MNE liegt im Median 2,0–4,0 cm daneben (Sog zu oberflächlichen Quellen), dSPM 3,2–4,5 cm.
- **Mit Rauschen (SNR 3):** Die Elektrodendichte entscheidet. sLORETA/eLORETA erreichen ≈ 0 –0,5 cm bei 64–128 Kanälen, 1,1–1,9 cm bei 16–32 und $\approx 3,5$ cm bei 8 Kanälen. Bei SNR 1 liegen

alle Verfahren bei 3–7 cm; dSPM ist dann am robustesten.

- **Verschmierung:** Die räumliche Streuung sinkt nur von $\approx 6,3$ cm (8 Kanäle) auf ≈ 4 cm (128 Kanäle), bei allen Verfahren ähnlich.

- **Kopfmodell:** Diese konkrete Abweichung verändert die Kennzahlen kaum; sie ist also mild. Unterschiede zwischen Standard- und individuellem Kopf können größer sein.




Abbildung 1. Median über 5124 Quellen (links, rechts) bzw. 4000 verrauschte Durchläufe (Mitte) je Elektrodenzahl; durchgezogen: Kopfmodell richtig, gestrichelt: Kopfmodell falsch; Fläche: Interquartilsabstand. Berechnet mit MNE-Python 1.13 (studie/aufloesung.py).

04 Diskussion: Was können wir aus dem EEG wissen?

Das inverse Problem des EEG ist unterbestimmt: Unendlich viele Quellverteilungen erzeugen dieselben Potentiale an der Kopfhaut (Helmholtz, 1853). Jedes Verfahren wählt eine Lösung nach einem Kriterium, das nicht aus den Daten stammt – kleinste Norm, Rauschnormierung, Standardisierung, exakte Punktlokalisierung. Die Studie zeigt, wo diese Vorannahmen tragen und wo nicht. sLORETA's Exaktheit ist real, aber bedingt; unter Rauschen wird Genauigkeit mit Elektroden erkaufte, und die nicht reduzierbare Verschmierung von mehreren Zentimetern bedeutet, dass ein „heißer Fleck“ eine statistische Zusammenfassung ist, kein Ort. Für die Neurowissenschaft ist das eine methodische Vorsicht; für die Wissenschaftsphilosophie ein klarer Fall modellabhängiger Beobachtung: Was als „Aktivität im Gehirn sehen“ gilt, hängt von den Annahmen ab, die im Instrument stecken.

05 Grenzen und nächste Schritte

Standardkopf und Standard-Elektrodenpositionen; Punktquellen und weißes Rauschen; die simulierten Aktivitäten sind didaktische Vereinfachungen. Nächste Schritte: farbiges Rauschen und ausgedehnte Quellen, ein individuelles Kopfmodell.

06 Echte Daten

Ein Modus „Echte Daten“ zeigt Gruppenkarten aus dem offenen PhysioNet-Datensatz EEG Motor

Movement/Imagery (40 Personen, 64 Kanäle): logarithmierte Bandleistungsverhältnisse, mit demselben Kopfmodell zurückgerechnet. Augen zu gegen offen (Alpha) hat sein Maximum in der linken lateralen Sehrinde; 98 % der stärksten 5 % der Quellen liegen okzipital oder parietal. Die vorgestellte Bewegung der linken Hand zeigt eine MuDesynchronisation über dem rechten Gyrus postcentralis (positive Lateralisierung bei 75 % der Personen, im Beta-Band 93 %); die rechte Hand zeigt das Spiegelbild.

07 Literatur

- Dale A. et al. (2000). Dynamic statistical parametric mapping. *Neuron* 26, 55–67.
- Fischl B. (2012). FreeSurfer. *NeuroImage* 62, 774–781.
- Gramfort A. et al. (2013). MEG and EEG data analysis with MNE-Python. *Front. Neurosci.* 7, 267.
- Hämäläinen M. & Ilmoniemi R. (1994). Interpreting magnetic fields of the brain: minimum norm estimates. *Med. Biol. Eng. Comput.* 32, 35–42.
- Hauk O., Stenroos M. & Treder M. (2022). Towards an objective evaluation of EEG/MEG source estimation methods – the linear approach. *NeuroImage* 255, 119177.
- Schalk G. et al. (2004). BCI2000: a general-purpose brain-computer interface system. *IEEE Trans. Biomed. Eng.* 51, 1034–1043.
- Pascual-Marqui R. D. (2002). Standardized low-resolution brain electromagnetic tomography (sLORETA). *Methods Find. Exp. Clin. Pharmacol.* 24D, 5–12.
- Pascual-Marqui R. D. (2007). Discrete, 3D distributed, linear imaging methods of electric neuronal activity. Part 1: exact, zero error localization. *arXiv:0710.3341*.