

Diss. ETH No. 20199

**A REAL TIME BRAIN MACHINE INTERFACE FOR
HAND GRASPING VIA SIGNALS FROM HIGHER
ORDER CORTICAL AREAS**

A dissertation submitted to the
ETH Zurich

for the degree of
Doctor of Sciences

presented by
ERK SUBAŞI

M.Sc. Computational Science, Koc University, Turkey
B.Sc. Electrical and Electronics Engineering, METU, Turkey
born May 29, 1980
citizen of Turkey

accepted on recommendation of
Prof. Dr. Rodney Douglas, examiner
Prof. Dr. Hansjörg Scherberger, co-examiner
Prof. Dr. Joachim Buhmann, co-examiner

Zürich, 2012

Abstract

Drawing on a wealth of knowledge about cortical movement processing, together with recent advances in signal processing and acquisition technology, the field of brain machine interfaces (BMIs) has the potential to become a viable assistive tool for patients with chronic spinal cord injury, stroke, and other motor debilitating diseases. Here, we present our efforts on development of a neural interface for decoding specific hand grasping postures in macaque monkeys. In contrast to the vast body of the literature, where M1 is used as the major source of motor related neural activity, our approach aims at decoding the neural activity in the anterior intraparietal cortex (AIP) and ventral premotor cortex (F5). These are higher-order motor planning areas, which play a role in sensorimotor integration during movement planning and believed to be holding an abstract representation of hand grasping actions. In this work, we formulated 3 main research questions and treated them subsequently;

First, as the major research question of this thesis, we investigated the feasibility of using multi-unit neural activity from AIP and F5 for decoding discrete hand postures in a real-time BMI setting with closed feedback. This approach builds upon the previous studies from our lab and targets conceptual proof of using neural signals from AIP and F5 in a real time setup with a clinical neuroprosthetic device ultimately in mind. Our initial analysis confirmed that real-time recorded signal characteristics have similar tuning properties to cells in previous single-unit recording studies. The maximum average decoding accuracy observed for two grasp types (power and precision grip) and five wrist orientations was 63% (chance level, 10%). Analysis of decoder performance showed that grip type decoding was highly accurate (90.6%), with most errors occurring during orientation classification. Furthermore, we observed significant differences in the contributions of F5 and AIP for grasp decoding, with F5 being better suited for classification of the grip type and AIP

contributing more toward decoding of object orientation. This work is published in *Journal of Neuroscience* in 2011 (Townsend et. al, 2011).

Second, using the same signal sources and modalities, we targeted decoding the temporal component of grasping, which has a fundamental importance in a realistic fully autonomous neuroprosthetic application. Employing initially the same analytical procedures from previous chapter we showed that, signals emerging from AIP and F5 are indeed usable for movement time decoding as well. Moving further we have utilized more sophisticated Markovian models to better capture stochastic and temporal structure of the underlying task and presented improved decoding accuracy and robustness. As the last attempt to draw a conclusion about maximum possible decoding accuracy, we defined our task in a data-mining setup and compared our results for different machine learning algorithms. Results have been presented in *Neuroscience 2008*, in Washington (Subasi et al., 2008).

Finally, similar to the last objective of temporal decoding, we took a data-mining approach for our initial task of decoding hand postures. Here, on our data set we systematically tested 24 different classification algorithms, which include standard machine learning algorithms and ensemble methods. Based on the observed results from different learner families, we have investigated the implementation of an improved learner for our problem. The proposed model showed better decoding accuracy and enhanced robustness on average compared to the learners utilized in the first part. However, at the end our benchmark learner, a Naïve Bayesian Classifier, was still showed to be one of the strongest learners for the task at hand. The outcome of this work was published and presented at an international IEEE conference (Subasi et al., 2010).

In sum, this thesis brings new insights into quantitative differences in the functional representation of grasp movements in AIP and F5 and represents a first step toward using these signals for developing functional neural interfaces for hand grasping.

Zusammenfassung

Das zunehmende Wissen über die Verarbeitung kortikaler Bewegungspläne und die neuesten Fortschritte in den Bereichen Signal- und Datenverarbeitung in Betracht ziehend, haben Gehirn-Maschine-Schnittstellen (engl. BMIs, “brain machine interfaces”) das Potential, eine zuverlässige Unterstützung für Schlaganfallpatienten, Patienten mit chronischen Rückenmarksverletzungen, und anderen degenerativen Krankheiten des motorischen Systems zu werden. In der vorliegenden Arbeit berichten wir von unseren Fortschritten bei der Entwicklung einer neuronalen Schnittstelle zur Dekodierung spezifischer Handgreifbewegungen bei Makaken. Im Gegensatz zum Grossteil der Veröffentlichungen in diesem Forschungsbereich, in denen M1 als Hauptquelle neuronaler Signale zur motorischen Kontrolle verwendet wird, zielt unsere Ansatz darauf ab, neuronale Aktivität in den Arealen AIP (dem anterioren intraparietalen Cortex) und F5 (dem ventralen prämotorischen Cortex) zu dekodieren. Es handelt sich dabei um übergeordnete motorische Areale, die im Rahmen der Bewegungsplanung eine Rolle bei der senso-motorischen Integration spielen und als Orte der abstrakten Repräsentation von Handgreifbewegungen gelten. In dieser Forschungsarbeit wurden drei zentrale Fragestellungen nacheinander untersucht.

Erstens untersuchten wir, als wissenschaftliche Kernfrage dieser Doktorarbeit, wie realistisch die Nutzung von neuronaler “Multi-Unit”-Aktivität der Areale AIP und F5 ist, um unterschiedliche Handbewegungen in einem Echtzeit-BMI-Setup mit geschlossener Rückkoppelungsschleife zu dekodieren. Dieser Ansatz baut auf vorhergehende Arbeiten unseres Labors auf und zielt darauf ab, einen konzeptionellen Beweis dafür zu liefern, dass neuronale Signale der Areale AIP und F5 in einem Echtzeit-Versuchsaufbau zur Bewegungs-Dekodierung benutzt werden koennen, nicht zuletzt hinsichtlich einer klinischen Umsetzung. Erste Analyse Ergebnisse bestätigten, dass die in Echtzeit aufgenommenen Signale in ihren Kodierungs-Eigenschaften vergleichbar mit den aus vorhergehenden Studien mit Einzelzelleableitungen gewonnenen Daten waren. Die maximale 6

Durchschnittsgenauigkeit für die Dekodierung zweier verschiedener Greifbewegungen (Kraft- und Präzisions-Griff) in Kombination mit fünf unterschiedlichen Ausrichtungen des Handgelenks lag bei 63% (bei einer Zufallswahrscheinlichkeit von 10%). Die Analyse der Leistungsfähigkeit des Decoders ergab eine hohe Genauigkeit bei der Dekodierung des Griff-Typs (90.6%), wohingegen die meisten Fehler bei der Unterscheidung der Orientierung des Handgelenks auftraten. Desweiteren beobachteten wir erhebliche Beitragsunterschiede von F5 und AIP zur Dekodierung der Greifbewegung, wobei die neuronale Aktivität in F5 besser für die Dekodierung des Griff-Typs geeignet war, jene in AIP dagegen mehr zur Dekodierung der Ausrichtung des zu greifenden Objekts beitrug. Diese Studie wurde 2011 im Journal of Neuroscience veröffentlicht (Townsend et al, 2011).

Zweitens zielten wir, unter Nutzung derselben experimentellen Daten, auf die Dekodierung der zeitlichen Komponente von Greifbewegungen ab. Dieser kommt eine zentrale Bedeutung für die praktische Umsetzung einer autonom funktionierenden neuroprothetischen Anwendung zu. Unter Verwendung derselben im Vorfeld gebrauchten analytischen Methoden zeigten wir, dass die neuronalen Signale der Areale AIP und F5 tatsächlich für die Dekodierung von zeitlichen Komponenten verwendet werden können. Im weiteren Verlauf benutzten wir anspruchsvollere Markov-Modelle, um stochastische Prozesse und die zeitliche Struktur des Versuchs detaillierter erfassen zu können, was zu einer verbesserten Genauigkeit und Verlässlichkeit der Dekodierung führte. Um ein abschliessendes Fazit zur höchstmöglichen Genauigkeit der Dekodierung zu ziehen, verglichen wir die Ergebnisse bei Benutzung unterschiedlicher Lern-Algorithmen miteinander. Die Ergebnisse wurden im Jahr 2008 im Rahmen der “Neuroscience” in Washington(D.C.) präsentiert (Subasi et al., 2008).

Schliesslich wählten wir, ähnlich der Analyse der zeitlichen Dekodierung, einen “Data-Mining”-Ansatz, um die ursprüngliche Frage nach der Dekodierung von Handgreifbewegungen zu beantworten. Hierbei untersuchten wir 24 unterschiedliche Klassifizierungs-Algorithmen, die standardisierte Lern-Algorithmen und “Ensemble

Methoden” beinhalteten. Basierend auf den beobachteten Ergebnissen bei Nutzung unterschiedlicher Familien von Lern-Algorithmen schlugen wir ein verbessertes Modell für unsere Fragestellung vor. Dieser Lern-Algorithmus zeigte im Schnitt eine verbesserte Dekodierungs-Genauigkeit und Zuverlässigkeit. Jedoch erwies sich am Schluss unser Referenz-Algorithmus, ein naiver Bayes-Klassifikator, als eines der besten Lern-Modelle für den gegebenen Task. Das Ergebnis dieser Arbeit wurde im Rahmen einer internationalen IEEE-Konferenz veröffentlicht und präsentiert (Subasi et al., 2010).

Zusammengefasst gewährt die vorliegende Dissertation neue Einblicke zu quantitative Unterschieden der funktionellen Repräsentation von Handgreifbewegungen in AIP und F5 und zeigt erste Schritte auf, wie diese Signale zur Entwicklung neuronaler Schnittstellen für Handgreifbewegungen genutzt werden könnten.