Kapitel 3

Modellierung eines Prädiktors

3.1 Methoden

Wie schon in der Einleitung erwähnt wurde, ist es üblich, Modellvorstellungen von den Vorgängen im Gehirn zu entwickeln. Konkrete Ausformulierungen solcher Modelle sind meist biokybernetische Schaltungen, die den neuronalen Signalfluß vereinfacht darstellen. Mit Hilfe solcher Modelle lassen sich Beobachtungen zusammenfassen und im günstigen Fall Hypothesen über die Signalverarbeitung falsifizieren. Es wurden insbesondere schon eine Reihe von Modellen entwickelt, die dazu beitragen sollen, ein Verständnis der prädiktiven Mechanismen zu entwickeln. In Anlehnung an die von Deno [14] vorgeschlagenen zwei Arten von Prädiktion, den auf kürzeren und den auf längeren Zeitskalen arbeitenden Mechanismen (s. 1.1), lassen sich die veröffentlichten Prädiktor-Modelle grob in zwei Klassen einteilen:

Prädiktoren, die auf einer Extrapolation der momentanen Zielgeschwindigkeit und ihrer Ableitungen basieren, wurden von Werner und Vossius [44] und von Lisberger et al. [32] vorgestellt. Werner und Vossius benutzen eine Taylor-Entwicklung der Zielposition, deren Koeffizienten aus der vergangenen Zieltrajektorie ermittelt werden. Lisberger et al. begnügen sich mit einer Extrapolation erster Ordnung.

Prädiktoren für metronomartige, periodische Zielbewegungen benutzen einen Frequenzdetektor, der dem System mitteilt, wann mit dem nächsten Reiz oder einer charakteristischen Reizänderung (etwa einer Umkehr der Bewegungsrichtung) zu rechnen ist. Barnes und Asselman [3] z.B. benutzen einen solchen Detektor, der in der intern berechneten, tatsächlichen Augengeschwindigkeit Periodizitäten ermittelt. Ähnlich funktioniert der „Target-Selective Adaptive Controller“ von Bahill und McDonald [2], ein phasengekoppelter Funktionengenerator. Dieser erreicht zwar eine Latenz von Null, allerdings benützen die Autoren im wesentlichen vorgespeicherte Zielbewegungsfunktionen.

Ein Modell eines prädiktiven Mechanismus, der in der Lage ist, periodische Zielbewegungen, mit denen er bisher nicht konfrontiert war, zu „erlernen“ und dadurch die Latenz von Folgebewegungen bezüglich der Zielbewegung zu reduzieren, fehlt in der Literatur.

Im Folgenden wird der Versuch unternommen, einen solchen Prädiktor in Form eines Neuronalen Netzes zu konstruieren und diesen in ein Modell für Folgebewegungen von Auge, Kopf und Arm zu integrieren. Gelingt der Versuch, so ist gezeigt, daß man zur Realisierung eines Prädiktors keine vorgespeicherten Funktionen in Form eines Funktionengenerators braucht, sondern daß schon ein relativ einfaches Netzwerk in der Lage ist, auch komplexere Zielbewegungen zu „erlernen“ und so Informationen zur Verkürzung von Reaktionszeiten zu gewinnen.

3.1.1 Neuronales Netz

Seit mehreren Jahrzehnten gibt es Bemühungen, die neuronale Struktur des Gehirns mit auf Digitalrechnern implementierten Modellen nachzubilden. Die so entwickelten Neuronalen Netze werden mittlerweile in vielen Bereichen erfolgreich eingesetzt. Sie sind vor allem zur Realisierung hochdimensionaler und nichtlinearer Abbildungen geeignet. Anwendung finden sie in der Zeitreihenanalyse (z.B. Aktienkurse), in Steuerungs- und Regelungsanlagen, in der Mustererkennung (z.B. Schrift- oder Spracherkennung) oder der Datenkompression und -aufbereitung. In der Gehirnforschung sollen Neuronale Netze vor allem das Verständnis für das Funktionieren der Signalverarbeitungsprozesse im Nervensystem erhöhen. Neuerdings werden die symmetrischen und homogenen Netze der Anfangszeit durch Strukturen ersetzt, die Erkenntnisse der Anatomie und Physiologie berücksichtigen. Einen Überblick über den Stand der Modellierung von Gehirnfunktionen gibt z.B. Cotteril [13].

Hier soll untersucht werden, ob ein relativ einfaches Neuronales Netz in der Lage ist, integriert in ein Modell für Folgebewegungen als Prädiktor zu arbeiten und ob sich damit experimentelle Ergebnisse aus dem ersten Teil dieser Arbeit reproduzieren lassen. Die Verwendung Neuronaler Netzwerke hat den Vorteil, daß sie die Möglichkeit bietet, Voraussagen über die Eigenschaften von Neuronen zu machen, die experimentell überprüft werden können. Es kann aber auch der umgekehrte Weg beschritten werden, nämlich Modellneurone mit experimentell ermittelten Eigenschaften zu versehen um die Leistung des auf ihnen basierenden Netzwerkes zu analysieren.

Wie kann nun die Struktur eines Prädiktor-Netzes aussehen? Weil die Eingangswerte gleichzeitig in das Netzwerk eingespeist werden, muß man zuerst die Annahme machen, daß die erkannte Zielgeschwindigkeit für eine gewisse Zeitspanne gespeichert werden kann. Wie groß man diese Zeitspanne wählen muß, ist zunächst nicht festgelegt. Ich wählte als Eingangsvektor für den Prädiktor elf Geschwindigkeitswerte im Abstand von 10 ms (Abbildung 3.1). Dieser Abstand ermöglichte eine ausreichende Abtastrate in dem 100 ms-Intervall. Aus diesen Werten $T(t_0 - t)$ mit $t = 0$ ms, 10 ms, ... , 100 ms sollte das trainierte Netz die zukünftige Zielgeschwindigkeit $T(t_0 + \Delta t)$ berechnen und damit dem Modellsystem ermöglichen, seine internen Verzögerungen (die v.a. den endlichen Reizleitungsgeschwindigkeiten im Nervensystem entsprechen) auszugleichen.

Als Neuronales Netzwerk verwendete ich ein dreistufiges Netz mit elf Eingängen, fünf

„hidden units“ und einem einzelnen Ausgang. Fünf „hidden units“ erwiesen sich im Laufe der Simulationen als kleinstmögliche Zahl, mit der ein Prädiktor auszustatten war, wenn er funktionieren sollte. Jeder der Eingänge e_i war mit jeder der „hidden units“ h_j gewichtet ($\boldsymbol{W}^2_{j,i}$) verbunden. Ihre Ausgänge führten, wieder gewichtet (w^1_j) zu der Ausgangszelle des Netzwerks. Mit der sigmoidalen Aktivierungsfunktion

$$f(x) = \frac{1}{1 + \exp(-x)} \tag{3.1}$$

und den Offset-Vektoren $\vec{o}_1$ und $\vec{o}_2$ gilt dann:

$$a = f(\vec{w}^1 \cdot \vec{h} + \vec{o}_1) \tag{3.2}$$

$$\vec{h} = f(\boldsymbol{W}^2 \cdot \vec{e} + \vec{o}_2). \tag{3.3}$$

Zum Trainieren des Netzwerks benutzte ich die bewährte „Backpropagation-Methode“, in der die Gewichte je nach Fehler verändert werden (Kinnebrock [25], S. 39 ff, Beweis der Konvergenz: S. 134 f). Es wurde ein Algorithmus mit variabler Lernrate und Impuls verwendet, wie er in Rumelhart et al. [39] und Vogl et al. [43] erläutert ist. Als Satz von Eingangsvektoren und Ausgangsgrößen zum Training benutzte ich die in Abbildung 3.1 symbolisch dargestellten Werte $T(t_{10}), \ldots, T(t_0)$ aus einer der im Experiment verwendeten Zielbewegungen, wobei ich den relevanten Zeitabschnitt in Schritten von 50 ms über den Datensatz hinwegschob. Dies entspricht einer Abtastrate von 20 Hz, was die maximale Stimulusfrequenz (1,5 Hz) um das mehr als 13fache übersteigt. Damit ist die Bedingung des Abtasttheorems, welches die doppelte Grenzfrequenz des Signals als Abtastrate fordert, erfüllt. Das Netzwerk wurde in 400 Zyklen jeweils mit allen aus dem Hinwegschieben gewonnenen Trainingsgrößen konfrontiert[1]. Für alle der 11 im Experiment verwendeten Parameterwerte k wurde das Netzwerk nicht während, sondern vor der Simulation trainiert („off-line“). Dem Fehler, mit dessen Hilfe das Netzwerk trainiert wird,

[1]Dadurch wurde erreicht, daß das Netz, wie auch die Versuchsperson im Experiment, für alle Parameterwerte die gleiche Zeit hatte, um sich auf die Stimulusbewegung einzustellen. Bei Definition einer Abbruchbedingung über eine Fehlergrenze wäre das nicht der Fall gewesen.

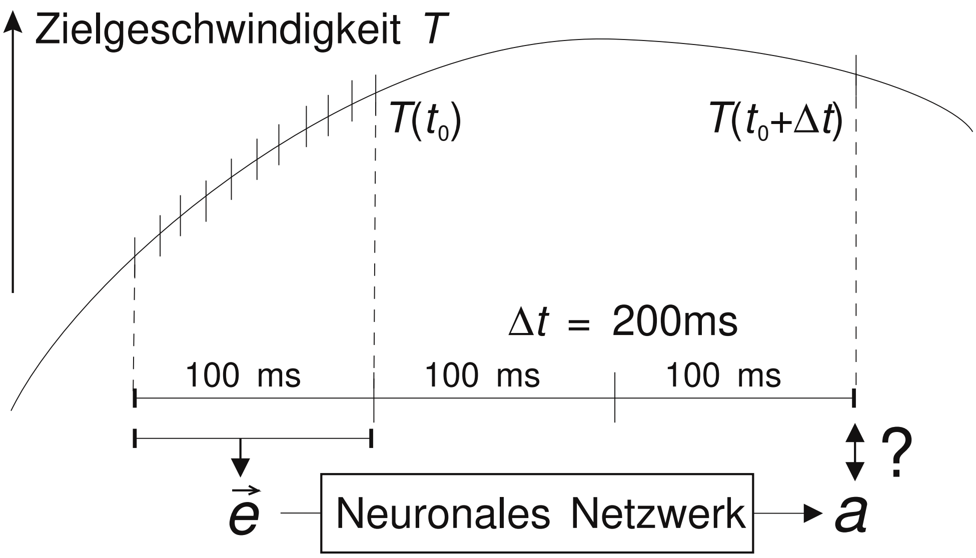

Abbildung 3.1: Das Neuronale Netzwerk soll aus 11 Eingangswerten $T(t_{10}), \ldots, T(t_0)$, die einem Abschnitt der Zielgeschwindigkeit entsprechen, die Geschwindigkeit $T(t_0 + \Delta t)$ zu einem späteren Zeitpunkt vorhersagen.

könnte in der Realität der retinale Fehler, d.h. der Abstand vom Ziel-Bild zur Fovea, entsprechen. Die bei der Simulation verwendete Testfunktion war nicht identisch mit der Trainingsfunktion, auch wenn sie mit dem selben Parameter k erzeugt worden war.

3.1.2 Erweiterung des CEHT-Modells: PCEHAT-Modell

Ein Modell für kombinierte Augen-Kopf-Folgebewegungen (combined eye-head-tracking, CEHT-Modell) wird in Dicke und Thier [15] vorgestellt. Eine detaillierte Darstellung dieses Modells, auf welchem das von mir verwendete beruht, ist im Anhang zu finden. Die zentralen Ideen bei diesem Modell sind

1. daß interne Rekonstruktionen von Augengeschwindigkeit relativ zum Kopf $\vec{E}$ und Kopfgeschwindigkeit im Raum $\vec{H}$ (Efferenzkopien) dazu benutzt werden, zusammen mit der Geschwindigkeit des Ziel-Bildes auf der Netzhaut $\vec{R}$ die Geschwindigkeit des Ziels im Raum $\vec{T'} = \vec{R} + \vec{E} + \vec{H}$ zu berechnen,

2. daß diese Größe $\vec{T'}$ das Eingangssignal für Augen- und Kopfmotorik bildet und schließlich,

3. daß die Kopfgeschwindigkeit von der des Auges im Raum abgezogen wird, so daß der Blick dem Ziel korrekt folgen kann (Dies ist gleichbedeutend mit der Aussage, daß bei kombinierten Kopf-Auge-Folgebewegungen der VOR aktiv ist. Lanman et al. [29]).

Der Grad der willkürlich bestimmten Beteiligung des Kopfes an der Bewegung läßt sich dabei von 0 bis 100% voreinstellen.

Ich erweiterte dieses Modell in zwei Punkten:

1. Ich nahm an, daß die Repräsentation der Zielgeschwindigkeit im Raum auch als Eingang für das Folgesystem des Armes dient. Dies entspricht der Variante mit einer „zentralen Zwischenstufe“ aus Abbildung 1.1. Weil Arm- und

Kopfmotorik in den Experimenten des ersten Teils große Übereinstimmung zeigten (Abschnitt 2.2.5), wurde das Folgesystem des Armes durch eine ähnliche Übertragungsfunktion wie das des Kopfes dargestellt[2].

2. Ich nahm ferner an, daß ein neuronaler Prädiktor genau diese Zielrepräsentation analysiert und die geschätzte Zielgeschwindigkeit zu einem Zeitpunkt in naher Zukunft ausgibt. Will man nur einen einzigen Prädiktor für alle Folgesysteme (Arm, Kopf und Auge) einsetzen, dann muß dieser Zeitpunkt so gewählt sein, daß er ihre durch Verzögerungselemente und Übertragungsfunktionen verursachten internen Verzögerungen gerade ausgleicht. Aufgrund der Unterschiede in diesen internen Verzögerungen ist man gezwungen, hier einen Kompromiß zu machen (Dies wäre ein Argument dafür, daß zumindest Teile der Prädiktion nicht von einer einheitlichen, zentralen Instanz, sondern für jedes der Systeme speziell verarbeitet werden.). Er liegt bei mir bei einer Vorhersagezeit von $\Delta t = 200$ ms.

Mit den geschilderten Änderungen verfügte ich also über ein Modell für prädiktive, kombinierte Augen-, Kopf- und Arm-Folgebewegungen (predictive combined eye-head-arm tracking, PCEHAT-Modell, Abbildung 3.2). Eine Frage ist nun, ob sich mit diesem Modell Ergebnisse aus den im ersten Teil dargestellten Experimenten reproduzieren lassen.

3.2 Simulationsergebnisse

3.2.1 Latenz, Kohärenz und vmse

Die Differentialgleichungen des PCEHAT-Modells wurden mit einem dynamischen Runge-Kutta-Verfahren fünfter Ordnung integriert. Die drei Versuchstypen des er-

[2]Der Unterschied besteht darin, daß die Zeitkonstanten statt 200 s^2 und 150 s bei der Übertragungsfunktion des Armes 150 s^2 und 100 s betragen.

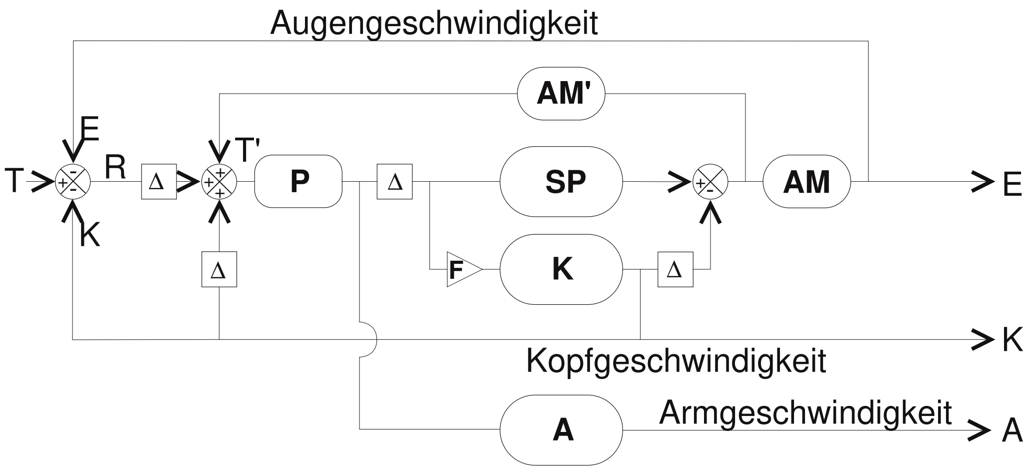

Abbildung 3.2: Das PCEHAT-Modell. Es sind: Δ: Verzögerungen, P: neuronaler Prädiktor, F: Kopf-Mitbewegungsfaktor (0..100%), SP: System für langsame Augenfolgebewegungen, K: Kopfmotorik, A: Armmotorik, AM: Augenmotorik, AM': interne Kopie der Augenmotorik; Geschwindigkeiten: T: Ziel im Raum, R: Zielbild auf der Retina, E: Auge im Kopf, K: Kopf im Raum, A: Arm im Raum, T': Rekonstruktion des Ziels im Raum

sten Teils (Ziel natürlich verfolgen, Ziel mit großem Kopf-Anteil verfolgen, Kopf fixiert) wurden simuliert, indem für die Mitbewegung des Kopfes 0, 50 und 95% angenommen wurde. Stimulusgeschwindigkeits-Funktionen vom gleichen Schwierigkeitsgrad (Parameter k) wie beim Training des neuronalen Prädiktors, aber nicht identische, bildeten den Eingang des Modells. Dies ist zulässig, weil es hier nicht darum ging, zu prüfen, in welchem Maß ein fertig trainiertes Netzwerk in der Lage ist, zu generalisieren, d.h. auch für andere als die gelernten Funktionen die Prädiktion zu leisten, sondern lediglich um die Frage, ob es möglich ist, ein Netzwerk auf diese Aufgabe hin erfolgreich zu trainieren. Es wurde aus Zeitgründen nur über eine Zeit von 10 s integriert und nicht über die vollen 50 s der Präsentationen im Experiment.

Abbildungen 2.13, 2.16 und 2.19 zeigen jeweils in der untersten Zeile die Kohärenzen, Latenzen und mittleren quadratischen Geschwindigkeitsfehler der Ausgangsfunktionen des Modells, die wie in 2.1.5 beschrieben berechnet wurden.

Die Kohärenzen fallen mit steigendem k von Werten über 0,98 auf bis zu 0,75 ab, was sich in etwa mit den experimentellen Daten deckt. Die Latenzen steigen, schneller als die experimentell ermittelten Latenzen, schon bei den ersten drei Parameterwerten auf ca. 300 ms an. Anstatt aber, wie im Experiment, darüber hinaus konstant zu bleiben, fallen sie rasch auf unter 100 ms ab. Die Latenzen unter 100 ms zeigen, daß die internen Verzögerungen größtenteils ausgeglichen werden können, da Auge, Kopf und Arm dem Ziel bei einem Modell ohne Prädiktor um 200-300 ms hinterherlaufen. In Abbildung 3.3 sind exemplarisch die Simulationsergebnisse für eine Kopfbeteiligung von 50% und Parameterwerte von $k = 0,\ 0,2$ und $0,8$ dargestellt.

3.2.2 Spektren

Die im Vergleich zu den Versuchen im ersten Teil um ein fünftel kürzere Dauer der einzelnen Stimulusbewegungen (10 s statt 50 s) zog eine kleinere Frequenzauflösung nach sich. Wie die Spektren der simulierten Geschwindigkeiten zeigen

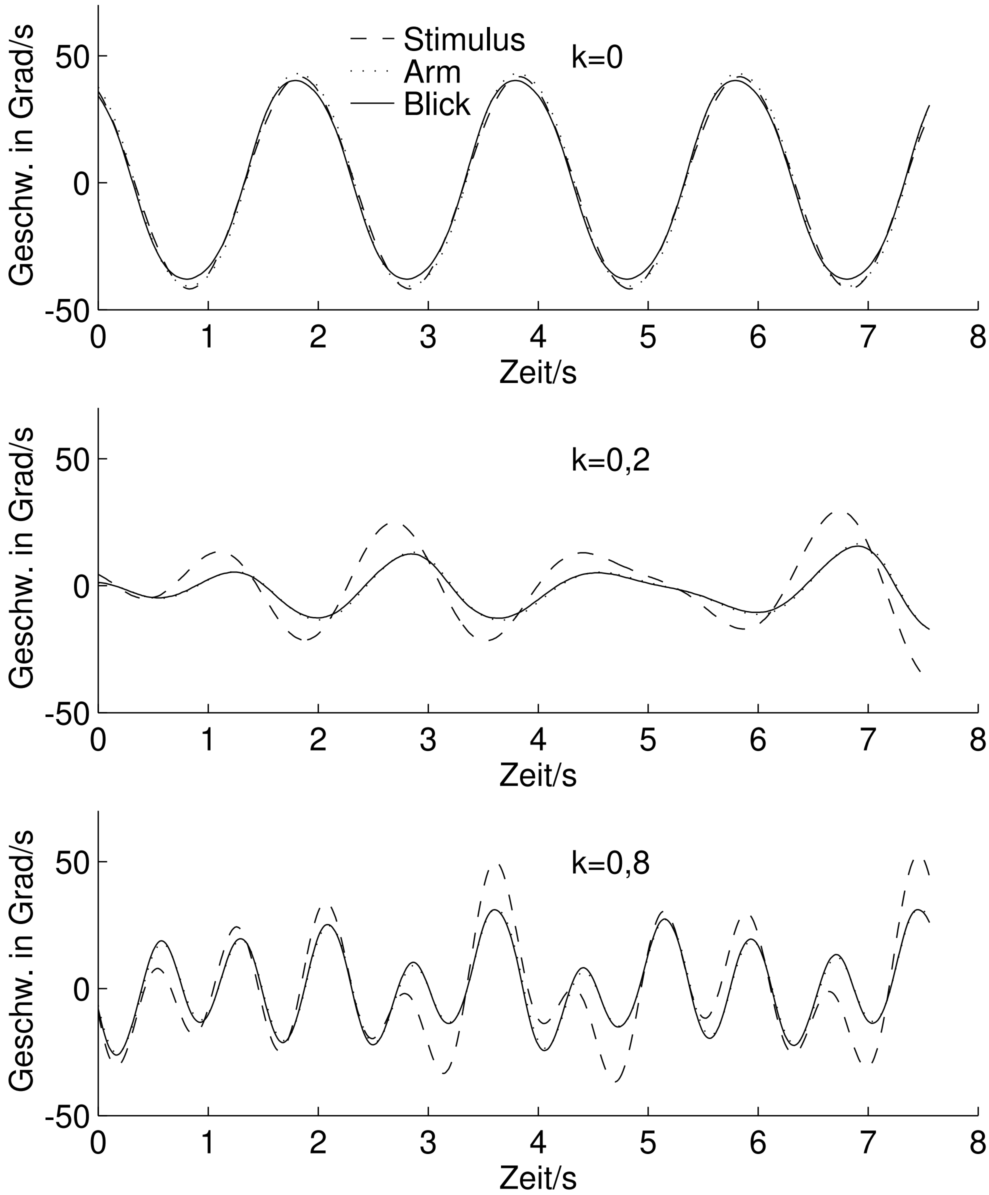

Abbildung 3.3: Beispiele simulierter Blick- (durchgezogen) und Armgeschwindigkeiten (gepunktet, Stimulusgeschwindigkeit gestrichelt). Die Parameterwerte betragen von oben nach unten $k = 0,\ 0,2$ und $0,8$ und zeigen damit gerade die Simulationen, bei denen die Latenz klein bzw. maximal ist.

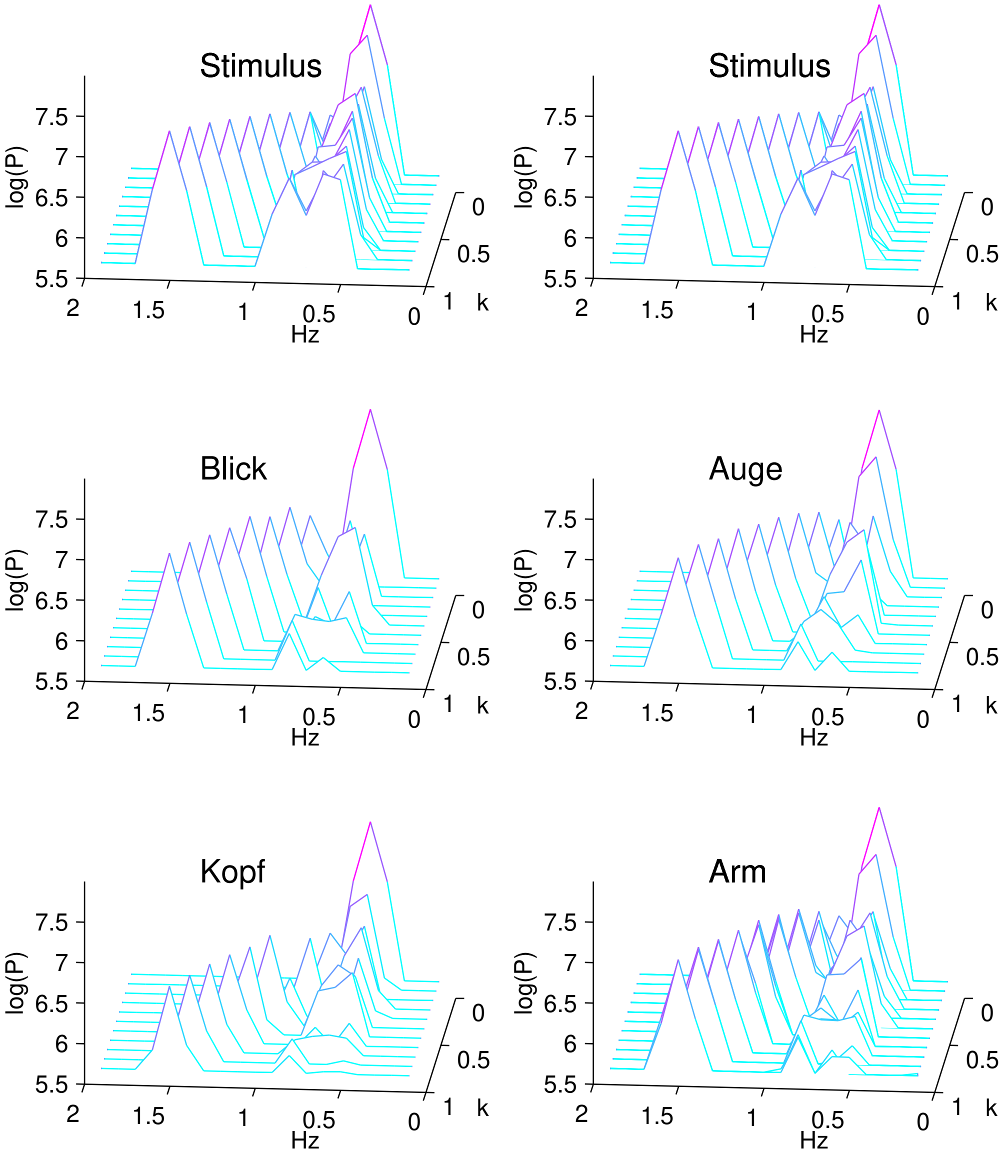

Abbildung 3.4: Spektren von Stimulus und simulierter Blick-, Augen-, Kopf- und Armbewegung. Die untere Schwelle zur Darstellung beträgt hier 5,7. Die Amplitudenquadrate der niedrigen Frequenzkomponenten sinken mit zunehmendem k wie bei einigen Versuchspersonen ab.

(Abbildung 3.4), konnte dennoch der bei einigen VP aufgetretene Effekt der Abschwächung der niedrigen beteiligten Frequenzanteile mit fallender Prädiktibilität der Zielbewegung (d.h. steigendem k) bei nahezu konstanter höchster Komponente reproduziert werden.

3.2.3 Reaktion auf ein Signal bandbegrenzten weißen Rauschens

Um einerseits diesen Abschwächungseffekt genauer zu studieren (Welcher Frequenzbereich ist davon betroffen? Wirkt das Modellsystem als Hochpaß oder als Bandpaß?), und andererseits die Reaktion des Neuronalen Netzes auf eine Funktion zu testen, die sich von seiner Trainingsfunktion stärker unterscheidet (also seine Generalisierungsfähigkeit), benutzte ich außerdem eine Mischung von 50 Sinus-Funktionen, die den Frequenzbereich von 0,5 bis 5 Hz abdeckten. Das Netzwerk wurde mit einer Zielbewegung trainiert, die einem Parameterwert von $k = 0,5$ entsprach. Aus Abbildung 3.5, die Simulationsergebnisse für eine Kopfbeteiligung von 50% zeigt, läßt sich entnehmen (indem man z.B. ausmißt, wie weit die lokalen Maxima auseinanderliegen), daß die Latenz, mit der der Zielbewegung gefolgt wird, bei ca. 150 ms liegt. Das bedeutet, daß, auch wenn die Trainingsfunktion nur Frequenzen von 0,5 Hz bis 1 Hz enthielt, der Prädiktor arbeitete und die internen Verzögerungen teilweise ausglich (Die Latenzen bei einem Modell ohne Prädiktor liegen bei 200-300 ms). Damit wird dem vorgestellten neuronalen Prädiktor eine, wenn auch begrenzte, Fähigkeit zur Generalisierung bescheinigt.

Abbildung 3.6 zeigt die Spektren der Simulationsergebnisse. Der beteiligte Frequenzbereich wird gut erfaßt. Seine Grenzen sind bei den simulierten Geschwindigkeitsspektren nicht ganz so scharf wie in den Spektren der Zielgeschwindigkeit. Eine Asymmetrie im Frequenzverhalten, etwa eine Abschwächung bei niedrigen beteiligten Frequenzen wie in den Spektren des vorherigen Abschnitts, ist hier nicht mehr

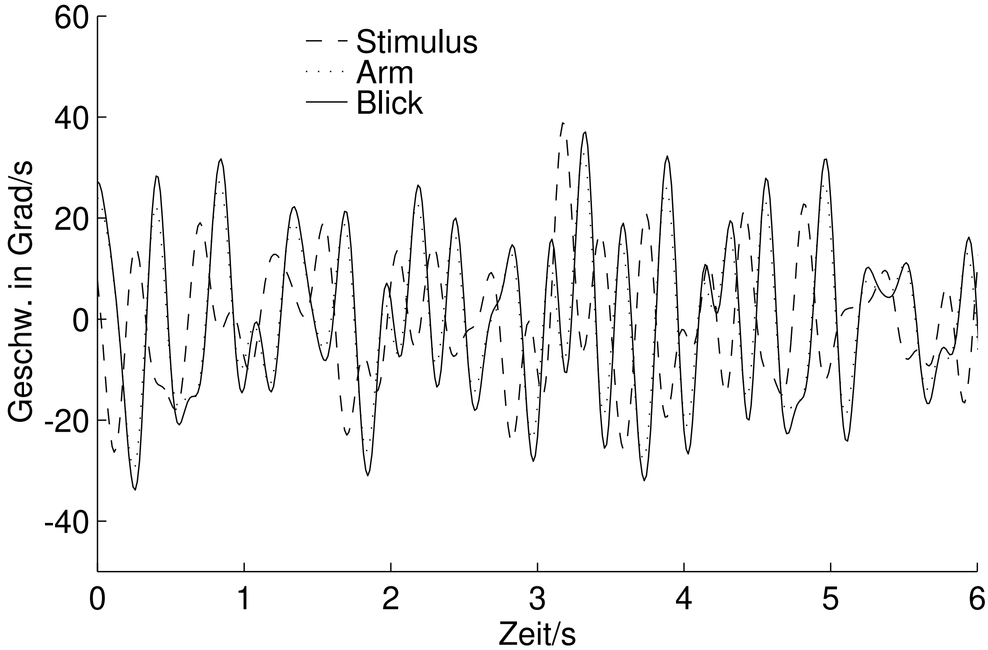

Abbildung 3.5: Simulationergebnisse bei einer Stimulusbewegung, die einen ganzen Frequenzbereich abdeckt. Arm- und Blickgeschwindigkeit laufen der Zielgeschwindigkeit um ca. 150 ms hinterher. Dies ist weniger, als bei einem Modell ohne Prädiktor.

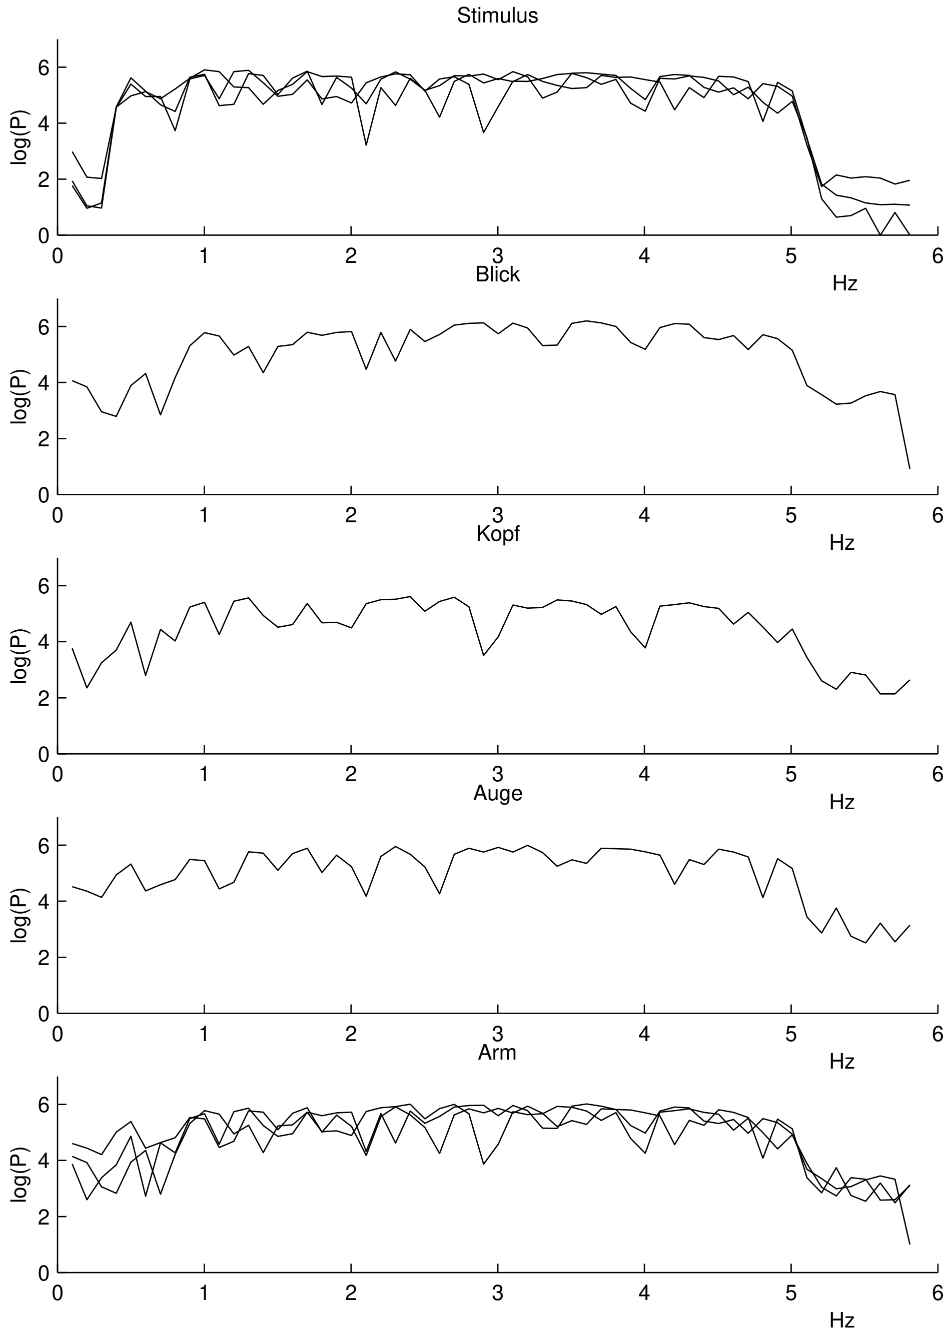

Abbildung 3.6: Spektren der Simulationergebnisse bei einer Stimulusbewegung, die einen ganzen Frequenzbereich abdeckt. Für Stimulus- und Armbewegung sind die Spektren aller drei Versuchstypen (Kopfbeteiligung 0%, 50% und 95%) angegeben. Das Modell mit neuronalem Prädiktor kann die Frequenzen des bandbegrenzten weißen Rauschens gut erfassen. Eine Bevorzugung höherer Frequenzen tritt hier nicht mehr auf.

zu erkennen. Das Hoch- oder Bandpaßverhalten des Modells scheint also von der speziellen Form der Eingangsfunktion abzuhängen.

Diese Eigenschaft des Modells könnte experimentell überprüft werden. Dazu müßte man die verschiedenen Spektren der Folgebewegungen von Versuchspersonen untersuchen, die sich durch Variation der Frequenzbereiche, aus denen die Zielbewegung aufgebaut ist, ergäben. Diese Experimente konnten aus Zeitgründen nicht mehr durchgeführt werden.