

Studienarbeit

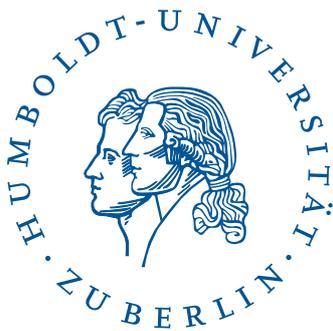
Erkennung von Kollisionen bei Robotergliedmaßen anhand von sensomotorischen Daten

Stefan Bethge

12. Mai 2011

Betreuer: Dr. Manfred Hild

Gutachter: Prof. Dr. Hans-Dieter Burkhard



Inhaltsverzeichnis

1. Einleitung	1
1.1. Motivation und Zielstellung	1
1.2. Bisherige Arbeiten zur Kollisionserkennung	2
2. Methode	2
2.1. Beschreibung der verwendeten Plattform	2
2.2. Experimentelle Datenaufnahme	3
2.3. Naive Bestimmung einer Kollision	6
2.4. Entwicklung der U-I-Kennlinie	6
2.5. Methode der kleinsten Quadrate	7
2.6. Erweiterung des Approximationsverfahrens	9
3. Implementation eines Echtzeitverfahrens	10
3.1. Numerische Berechnung des Trainingsvektors	10
3.2. Neuronale Struktur zur Kollisionsermittlung auf einem Roboter	11
4. Analyse und Auswertung der praktischen Verwendbarkeit	13
4.1. Betrachtung einer minimierten Basis	13
4.2. Vergleich verschiedener Basen und Gliedmaßen	14
5. Zusammenfassung und Ausblick	19
Anhang A. Anpassen von Parametern der neuronalen Netze an spezifische Hardware	20
Anhang B. Weitere Messdaten	21

1. Einleitung

1.1. Motivation und Zielstellung

In der Entwicklung von kognitiven Fähigkeiten eines Roboters, die die Umwelt und den eigenen Körper wahrnehmen, sind die im Vergleich zu natürlichen Organismen geringe Anzahl vorhandener Sensoren eines der Probleme, auftretende Situationen angemessen zu erkennen und darauf zu reagieren. Neben deliberativen Ansätzen, die eine ausführliche Modellierung der Umwelt als Basis für eine Handlungsplanung verwenden, ist es nach dem Vorbild der Natur vorteilhaft, die Welt selbst als Modell zu verwenden, das heißt keine geometrischen Berechnungen in Erwartung bestimmter räumlicher Beschaffenheit anzustellen, sondern die Umwelt zu erkunden und Rückkopplungen als Antwort dieser anzusehen. Dafür ist es jedoch nötig, möglichst viele hochwertige und verschiedenartige Sensordaten zur Verfügung zu haben. Hochentwickelte kognitive Fähigkeiten bei Säugetieren werden nicht zuletzt durch mehrere Millionen einzelner sensorischer Zellen möglich, die zudem in Kombination weit aussagefähiger sein können. Vergleichbar viele Sensoren sind aus technischen und finanziellen Gründen bei Robotern meist nicht möglich, so dass es von Vorteil ist, mit den vorhandenen Sensoren auch auf nicht direkt gemessene Ereignisse schließen zu können.

Die in dieser Arbeit betrachteten Gliedmaßen eines humanoiden Roboters sind nicht mit speziellen Berührungssensoren ausgestattet, die z.B. ähnlich der Haut von Wirbeltieren an beliebiger Position eine Druckinformation liefern könnten. Bei Bewegungen eines Gliedmaßes ist es aber immer möglich und wahrscheinlich, dass Hindernisse oder der eigene Körper die Bewegung erschweren oder verhindern und daher eine Änderung der Bewegung notwendig wird. Wenn Roboter mit Menschen interagieren, ist zudem die Frage interessant, inwieweit das Verhalten den Menschen gefährden kann. Auch Anwendungen in der autonomen Erkundung der Umgebung sind möglich. Zudem ist es nicht zuletzt wünschenswert, Motoren und Material zu schonen.

Im Folgenden soll also die mögliche Zuordnung bestimmter Muster von vorhandenen Standardsensoren zu Kontakt- und Kollisionen mit Hindernissen untersucht werden. Es ist eine Methode gesucht, die auch auf der in der Robotik meist begrenzten Hardware effizient und mit möglichst geringer Verzögerung berechnet werden kann.

1.2. Bisherige Arbeiten zur Kollisionserkennung

Das Problem der Kollisionserkennung bei Robotern ist nicht neu und wurde in verschiedenen Arbeiten untersucht. Dabei werden jedoch bei vielen Plattformen und Umsetzungen gewünschte Trajektorien aus einem Modell heraus berechnet und so die Aktuatoren mit gewünschten Winkeln angesteuert, wie z.B. bei [Quinlan et al. 2003]. Eine Kollisionserkennung wird dann durch Beobachten der tatsächlichen Trajektorie im Vergleich zur Angestrebten erreicht. Obwohl dadurch teils eine hohe Reaktivität erreicht wird, ist es dadurch auch schwieriger, gewollte Hindernisse von ungewollten zu Unterscheiden, z.B. bei einer Schiebebewegung oder Bewegung gegen die Schwerkraft, da die auftretenden Gegenkräfte immer Teil des damit komplexeren Modells der Umwelt sein müssen. Die in dieser Arbeit betrachtete Ansteuerung verzichtet bewusst auf eine Winkelpositionierung der Aktuatoren, um stattdessen mit Kräften zu arbeiten, so dass Rückkopplungen, Inhibitionen und externe Beeinflussung möglich wird.

In [Quinlan et al. 2004] wird eine Erkennung durch Support Vector Machines beschrieben, die in der Herangehensweise mit dieser Arbeit vergleichbar, jedoch in der Berechnung sehr viel aufwändiger ist. Anscheinend wurde aber auch keine besonders hohe Genauigkeit erreicht, da nur die stärksten Kollisionen erkannt wurden. Dies kann unter Umständen auf die möglichen Probleme beim Einstellen der für die SVM notwendigen Parameter zurückgeführt werden.

2. Methode

2.1. Beschreibung der verwendeten Plattform

Der in Abbildung 1 dargestellte humanoide Roboter *Myon* wurde am Labor für Neurorobotik der Humboldt-Universität zu Berlin im Rahmen des Projektes ALEAR¹ entwickelt. Besonders hervorzuheben gegenüber vergleichbaren humanoiden Robotern ist die Eigenschaft, durch vollständig autonome Körperteile nicht von einer zentralen Steuerung abhängig zu sein. Dadurch ist es möglich, auch während der Laufzeit einzelne Körperteile abzunehmen und Experimente an diesen isoliert zu betrachten und darauf entwickelte Verfahren später wieder mit anderen Komponenten zusammenzufügen.

Die verwendeten Aktuatoren besitzen an den mechanisch stärker belasteten Gelenken der Knie und Schultern mit Federn versehene Abtriebe (siehe Abb. 11), die zu starke Belastung der Motoren kompensieren und zudem nach biologischem Vorbild zur besseren Energieeffizienz des Laufens verwendet werden können, indem beim Aufsetzen Bewegungsenergie durch die

¹Weiteres zum Projekt ist unter <http://alear.eu> zu finden.

Federspannung gespeichert wird, so dass diese beim Abstoßen wieder als kinetische Energie zurückgewonnen wird (vgl. [Migliore et al. 2010] und [Hild et al. 2011]).



Abbildung 1: Modularer humanoider Roboter *Myon* mit vollständig angebrachtem Exoskelett und allen Körperteilen. Der linke Arm wurde für die weiteren Untersuchungen isoliert verwendet, wie in Abbildung 2 dargestellt.

2.2. Experimentelle Datenaufnahme

Um ein stabiles Verfahren zu finden, ist der erste Schritt, Messdaten von Kollisionsversuchen aufzunehmen, die den realen Gegebenheiten der zu erkennenden Situation möglichst ähnlich sind. Diese werden in den folgenden Abschnitten zur Ableitung eines Kollisionsfalls untersucht und verwendet.

In Abbildung 2 ist ein linker Arm der Roboterplattform *Myon* zu sehen, wie er zur Aufnahme von Sensordaten verwendet wurde.

Die verschiedenen Experimente bestehen aus drei unterschiedlichen Belastungen des Arms mit je vier Geschwindigkeiten in positiver und negativer Richtung. Dabei wurde der Arm nach einer kurzen Startverzögerung mit konstanter Winkelgeschwindigkeit $\omega \in [\pm 0,003; \pm 0,008; \pm 0,015; \pm 0,03]$ in $\frac{\text{deg}}{\Delta t}$ angesteuert, welche durch einen PID-Regler geregelt wurde. Die externen Winkelencoder haben einen Wertebereich von etwa 300° , welcher

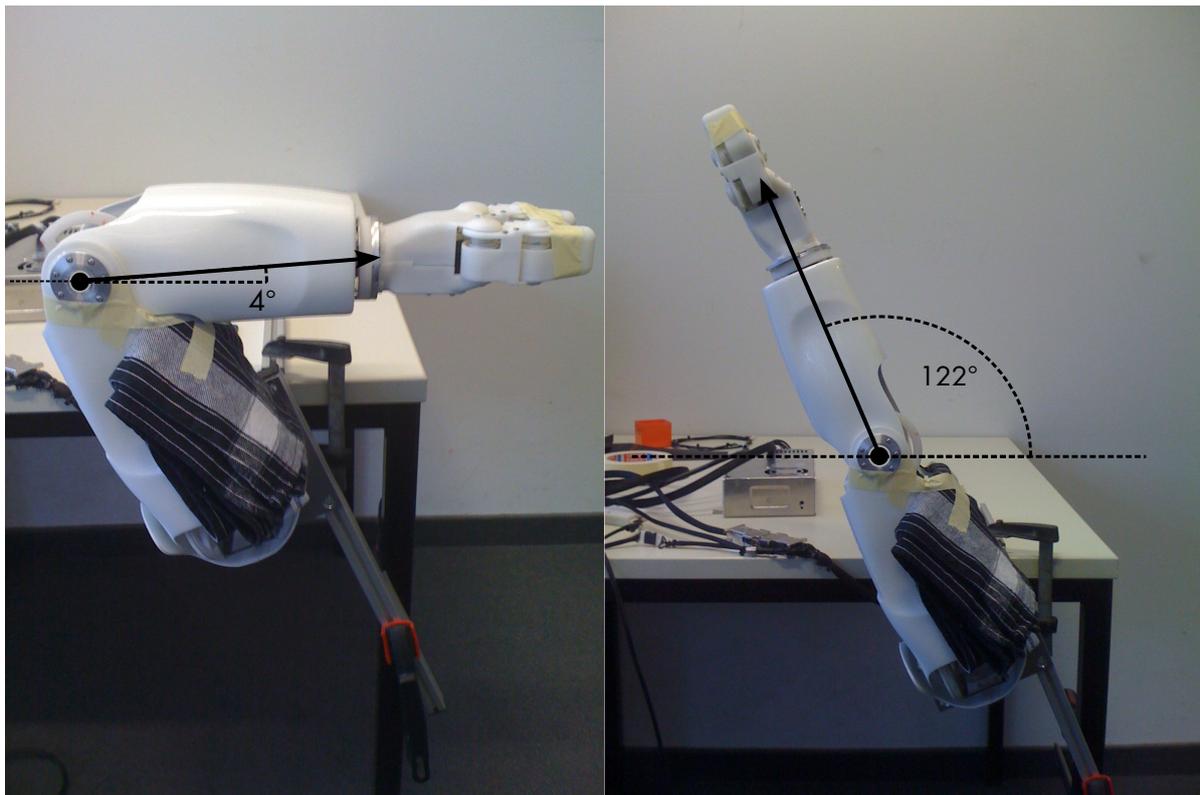


Abbildung 2: Befestigung des isolierten Armes zur Messdatengewinnung. Die eingezeichneten Winkel stellen die maximalen Auslenkungen des Armes dar. Dabei ist links im Bild der Anschlag in negativer Richtung gegen die weiße Verschalung mit festem Polster und rechts der Anschlag in positiver Richtung gegen das innere Aluminiumgestell dargestellt. Der Arm ist in Richtung der Koronalebene (hier ins Bild hinein) gegen ein Polster fixiert, um eine Lageveränderung zwischen den Versuchen zu verhindern. Weiterhin wurde ein Handtuch als Polster verwendet, um die Verschalung bei wiederholtem Aufschlagen zu schonen.

auf das Intervall $[0, 1]$ abgebildet wird, so dass Geschwindigkeiten daher in $\frac{3,6}{3}$ Grad pro Zeitschritt ($\Delta t = 10$ ms) zu verstehen sind. Während die erste Versuchsreihe mit dem Arm ohne angesteckten Greifer durchgeführt wurde, sind die zweite Versuchsreihe mit Greifer (+ 250g) und die dritte Versuchsreihe mit einem zusätzlichen Aluminiumzylinder als Gewicht (+ 74g) durchgeführt worden. Diese Gewichtsvariierung stellt eine praktisch durchaus mögliche Benutzung des Armes dar, die erfordert, dass ein robustes Verfahren gegenüber verschiedenen Belastungen stabil sein muss. Außerdem ist zu erwarten, dass Bewegungen gegen die Gravitationskraft andere Verhältnisse der Sensorsignale aufweisen als Bewegungen mit der Gravitation.

Die aufgenommenen Messdaten sind in den Abbildungen 13 und 14 dargestellt, bei denen

die gemessene Spannung $U(t)$, der Strom $I(t)$ und der aktuelle Winkel $\varphi(t)$ abgetragen sind. Die Winkelgeschwindigkeit $\omega(t) := \frac{d}{dt}\varphi = \dot{\varphi}$ wird mit $\hat{\omega}(t) \approx \varphi(t) - \varphi(t-1)$ angenähert. Außerdem ist der Winkelversatz $d(t)$ angegeben, der sich aus der Differenz der beiden Winkelencoder, innerhalb des Dynamixel RX-28-Servos und extern an der Achse, berechnet (*“angular displacement”*) und damit eine interne Verspannung angeben (vergl. [Hild et al. 2011]). Da die beiden Sensoren nicht den gleichen Wertebereich besitzen, ist eine von der konkreten Hardware abhängige Skalierung auf einen Wertebereich von 1 und eine Mittelwertzentrierung notwendig. Es ist zu erwarten, dass der Winkelversatz größer wird, je stärker der Motor auf den Abtrieb einwirkt, während dieser sich nicht bewegt. Die abgetragene Zeit ist in den folgenden Graphen in diskreten Zeitschritten mit $\Delta t = 10$ ms angegeben.

In den Graphen ist zu erkennen, dass Spannung, Winkelgeschwindigkeit und Winkelversatz vorzeichenbehaftet sind, je nach Bewegungsrichtung. Der gemessene Strom ist dagegen immer positiv. Bei einer Kollision, welche hier anhand der Veränderung des Winkels, also der Geschwindigkeit abgelesen werden kann, fällt letztere in wenigen Zeitschritten auf Null und der Strom und der Betrag von Spannung und Winkelversatz steigen an. Der Anstieg resultiert aus der Ansteuerung durch einen PID-Regler, der eine konstante Geschwindigkeit anstrebt und bei abfallendem ω entsprechend die Stromstärke ansteigt. Eine geschwindigkeitsgeregelter Ansteuerung wird für das hier betrachtete Szenario vorausgesetzt. Das Abfallen aller Werte nach der Kollision ist dem manuellen Abschalten zum Versuchsende geschuldet.

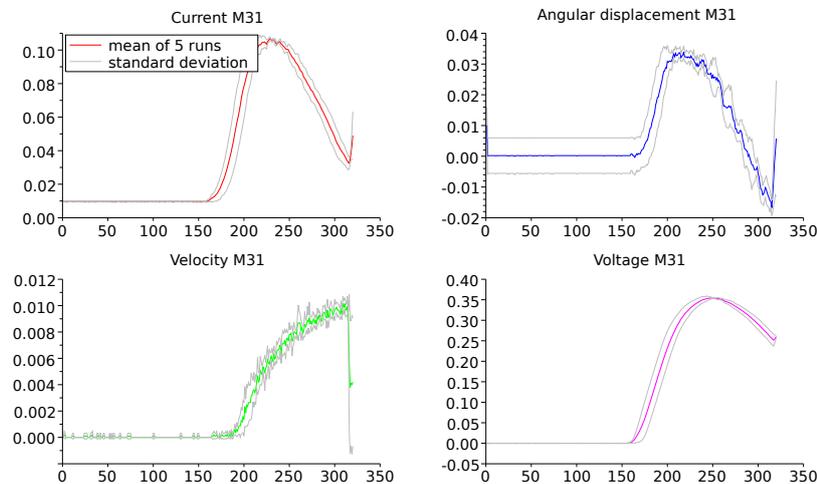


Abbildung 3: Streuung und Mittelwerte der verschiedenen Sensorwerte zwischen Fünf Versuchswiederholungen mit gleichen Parametern. Die Betrachtung zeigt, dass die Streuung zwischen den Versuchen eher gering ist, so dass mit jeweils einem Versuch statt einer Mittelung weiter gearbeitet wurde.

2.3. Naive Bestimmung einer Kollision

Intuitiv lässt sich anhand der Diagramme eine Bedingung formulieren, die der Kollision ähnliche Situationen ausschließt. Die dafür wichtigen Größen scheinen die Spannung U und die Geschwindigkeit ω zu sein. Der Winkel selbst kann nicht mit Einfließen, da die Erkennung von der Position unabhängig sein soll um nicht nur die eigenen Anschläge zu erkennen. Ausschließlich die abfallende Geschwindigkeit ist nicht ausreichend, da nur bei einer Ansteuerung U auch eine Kollision auftreten kann und auch der Ruhezustand die Geschwindigkeit Null besitzt. Da der Strom bei einer Beschleunigung des Arms einen ähnlichen Anstieg besitzt wie bei einer Kollision (die konstante Regelung der Geschwindigkeit führt jeweils zum Ansteigen des Stroms), sollte zusätzlich die ansteigende bzw. stark fallende Geschwindigkeit einbezogen werden, also die Beschleunigung $\dot{\omega}$. Eine Kollision tritt dann auf, wenn die Beschleunigung negativ wird und der Strom gleichzeitig ansteigt. Ebenfalls wurde die Verspannung des Gelenks gegen die materialbedingte Elastizität betrachtet. Diese ist weniger aussagekräftig als erwartet, da sie weder die nötige Empfindlichkeit, noch signifikante unterschiedliche Ausprägung im Vergleich von Kollisions- und Beschleunigungsfall aufweist. Zudem ist sie einem Offset unterlegen, der von der vorherigen Bewegung abhängt. Dieser ist in den Graphen nach jedem einzelnen Versuch zu erkennen.

Letztendlich konnte eine einfache experimentelle Kombination dieser Größen nicht zur gewünschten Sensibilität und Robustheit geführt werden, insbesondere da in Randsituationen auch hektische Richtungswechsel als Kollision erkannt wurden.

2.4. Entwicklung der U-I-Kennlinie

Statt direkt die Sensorwerte zu betrachten, ist es auch möglich, das Verhältnis zwischen Strom und Spannung zu betrachten, welches dem internen Widerstand des Motors entspricht. Obwohl deutliche Unterschiede im Anstieg zu erkennen sind, wurde diese Möglichkeit nicht weiter verfolgt, da anhand der Graphen über die Spanne der verschiedenen Anstiege der Kurven keine einfache untere Schranke für "Kollision" gefunden werden konnte. Insbesondere bei kleiner Geschwindigkeit sind Beschleunigung und Kollision kaum zu unterscheiden. Innerhalb eines Versuchs ist der Unterschied zwischen freier Bewegung und Kollision anhand der Richtungsänderung von fallender zu steigender Kurve gut zu erkennen. Es müsste also eine genaue und robuste Erkennung dieser Steigerungsveränderung implementiert werden. Nach der Kollision verändert sich der Anstieg in den meisten Versuchen kaum, so dass bei kleinen Geschwindigkeiten auch nach kurzer Zeit eine Kollision nicht deutlicher zu erkennen ist.

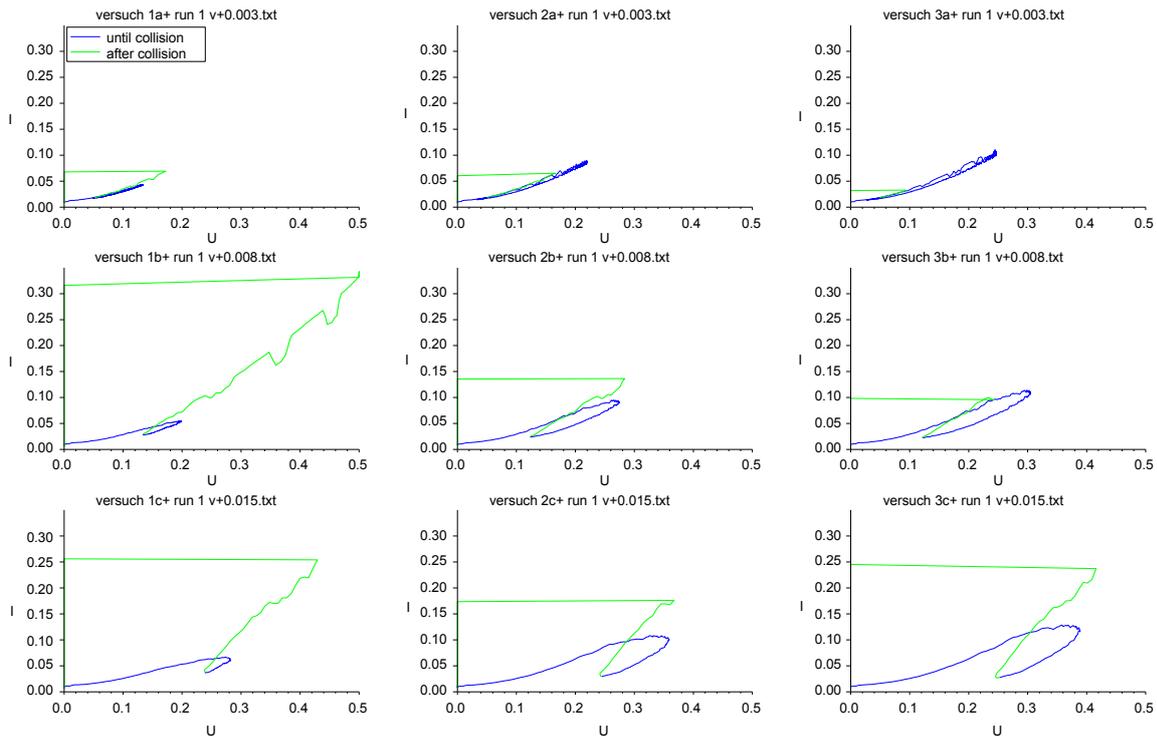


Abbildung 4: U-I-Diagramme für positive Versuche. Die verschiedenen Phasen der Versuche sind durch verschiedene Farben gekennzeichnet.

2.5. Methode der kleinsten Quadrate

Eine weitere Möglichkeit mehrere Sensordaten gleichzeitig zu betrachten ist es, die Fragestellung als Klassifikationsproblem im Sensorraum aufzufassen. Die Klassifikation besteht im wesentlichen darin, eine lineare Regression auf numerisch kodierten Klassen durchzuführen (vgl. [Wolberg 2006]). Wie zuvor festgestellt, ist es zur Unterscheidung von Beschleunigung und Kollision notwendig, mehrere Größen in Betracht zu ziehen. Nach der allgemeinen Methode in diesem Abschnitt wird im nächsten Abschnitt genauer beschrieben, wie durch Erweiterung des Sensorraumes die Klassifikation verbessert werden kann.

Für das hier betrachtete Problem wird zu n Versuchsdaten eine Vektor $\vec{y} \in \mathbb{R}^n$ konstruiert, deren Elemente y_i an den entsprechenden Zeitschritten einer beobachteten Kollision einen Peak bei Eins besitzen, ansonsten gilt $y_i = -1$. Dieser dient als abhängige Variable für die Regression. Diese Peaks können von unterschiedlicher Form sein und sich damit auf die Qualität der Klassifikation auswirken. Neben Impuls, linearer Rampe und sinoider Kurvenform hat sich letztendlich ein exponentieller Anstieg als vorteilhaft erwiesen, da er dem Verlauf des wichtigsten Koeffizienten, dem Strom, entspricht und die Fehlersumme

damit klein bleibt. Eine gute Klassifikation bedeutet eine möglichst geringe Abweichung der numerischen Klassifikation vom Modellvektor \vec{y} in jedem Zeitschritt. Die aufgenommenen Sensordaten der in Abschnitt 2.2 beschriebenen Versuche wurden so hintereinander gefügt, dass eine Folge von gleich vielen Versuchen mit Kollision und Bewegung ohne Kollision entsteht.

Die Abbildung dieser Sensordaten auf die angestrebte Klassifikation \vec{y} lässt sich als lineares Gleichungssystem darstellen, das die Abhängigkeit von einem Gewichtsvektor \vec{w} und der Matrix X mit m Sensordaten über einem Zeitbereich ausdrückt (Die angegebenen Vektoren sollen hier Zeilenvektoren sein). Mit $\vec{y} \in \mathbb{R}^n$, $\vec{w} \in \mathbb{R}^m$ und $X \in \mathbb{R}^{m \times n}$ gelte

$$\vec{y} = \vec{w} \cdot X$$

Dabei ist der Vektor \vec{w} gesucht. Nachdem er für einen repräsentativen Datensatz X bestimmt wurde, kann er benutzt werden, um unbekannte \vec{y} zu berechnen, die dem zuvor konstruierten \vec{y} entsprechen. Sofern X invertierbar ist, kann \vec{w} durch einfache Umformung ermittelt werden: $\vec{y} \cdot X^{-1} = \vec{w}$. In den meisten Fällen ist X aber nicht quadratisch und invertierbar. Eine Möglichkeit, dennoch eine approximative Lösung für das Gleichungssystem zu erhalten, ist eine verallgemeinerte Inverse oder Pseudoinverse nach Moore-Penrose ([Moore 1920]), welche auch für singuläre und nichtquadratische Matrizen definiert ist. Sind die Spalten von X linear unabhängig, lässt sich nach Erweiterung mit der Transponierten von X

$$\vec{y} \cdot X^T = \vec{w} \underbrace{(X \cdot X^T)}_{\text{quadr.}}$$

$X \cdot X^T$ invertieren und damit die Gleichung nach \vec{w} umstellen. X^+ ist die Pseudoinverse.

$$\vec{y} \cdot \underbrace{[X^T (X \cdot X^T)^{-1}]}_{X^+} = \vec{w}$$

Hat X vollen Rang, ist das so berechnete \vec{w} zudem die einzige Lösung.

Die *Methode der kleinsten Quadrate* hat das Ziel, \vec{w} so zu wählen, dass eine Approximation mit möglichst geringem Fehler entsteht. Die zu minimierende Fehlersumme ist die quadrierte Abweichung des Modellvektors von den Sensordaten im jeweiligen Zeitschritt j .

$$S := \sum_{i=1}^n (\omega_i \cdot x_{i,j} - y_i)^2 = \|\vec{w} \cdot \vec{x}_j - \vec{y}\|^2$$

Die Lösung der Gleichung $\vec{y} = \vec{w} \cdot X$ minimiert $\|\vec{w} \cdot X - \vec{y}\|$, berechnet also die least-squares-Approximation. Die Berechnung mit der Pseudoinversen ergibt auch bei nicht vollständigem Rang von X die optimale Lösung der möglichen least squares-Lösungen.

Geometrisch lässt sich die Lösung anhand des Vector Space Models interpretieren, welches das Skalarprodukt $\vec{w} \circ \vec{x}_i$ als Winkel im jeweiligen Hyperraum und damit als Abstands- bzw. Ähnlichkeitsmaß sieht, im Gegensatz zum VSM entfällt die Normierung der Vektoren hier aber. \vec{w} ist damit der Idealvektor für freie Bewegung, großer Abstand von diesem die Kollision. \vec{y} ist die Abstandsfunktion über der Zeit.

Die Methode der kleinsten Quadrate macht Verteilungsannahmen über die Messfehler der Sensordaten. Die Messfehler sollen unkorreliert sein und die gleiche Varianz besitzen (Satz von Gauß-Markov, vgl. [Markov 1912]). Diese Bedingungen sind durch die Art der Messfehler erfüllt, die fast ausschließlich aus Sensorrauschen bestehen. Da deutlich mehr Messpunkte als verschiedene Parameter vorliegen, haben eventueller Ausreißer nur geringen Einfluss.

2.6. Erweiterung des Approximationsverfahrens

Bisher wird lediglich eine Linearkombination der Sensorwerte selbst vorgenommen, was nicht zu besonders guten Ergebnissen führt. Anstatt eine nichtlineare Variante der Methode zu verwenden, kann die Basis des Sensorraums erweitert werden, wodurch trotz linearer Kombination auch nichtlineare Funktionen verwendet werden können und so dass der Sensorraum nichtlinear verzerrt wird. Für die Experimente wurde die ursprüngliche Basis mit den zweiten und dritten Potenzen der Größen Strom, Spannung, Geschwindigkeit und Winkelversatz und den jeweiligen Kombinationen erweitert. Außerdem wurden zu jedem Zeitschritt Werte aus vorherigen Zeitschritten von einzelnen Größen in einer jeweiligen weiteren Dimension wiederholt (*time-embedding*). Nach einer Normalisierung der Messdaten mit der Standardabweichung lassen sich die ermittelten Gewichte w_i vergleichen und so Parameter mit kleinem Einfluss entfernen. So konnte der Sensorraum von 51 Dimensionen auf immerhin 32 bei schwachem Fehlerzuwachs reduziert werden. Jedoch sind nicht alle kleinen Gewichte prinzipiell weniger wichtig, da die Dimensionen verschiedene Semantik besitzen und sich diese Bedeutsamkeit nicht unbedingt in den Zahlenwerten niederschlägt. Die Ermittlung weniger wichtiger Koeffizienten ist also immer auch ein iterativer Prozess. Eine Approximation mit ausgewählten Versuchen aus Abbildung 13 und 14 sind in Abbildung 5 dargestellt. Eine beispielhafte Klassifikation auf Versuchsdaten, die nicht zum trainieren verwendet wurden, ist in Abbildung 15 dargestellt.

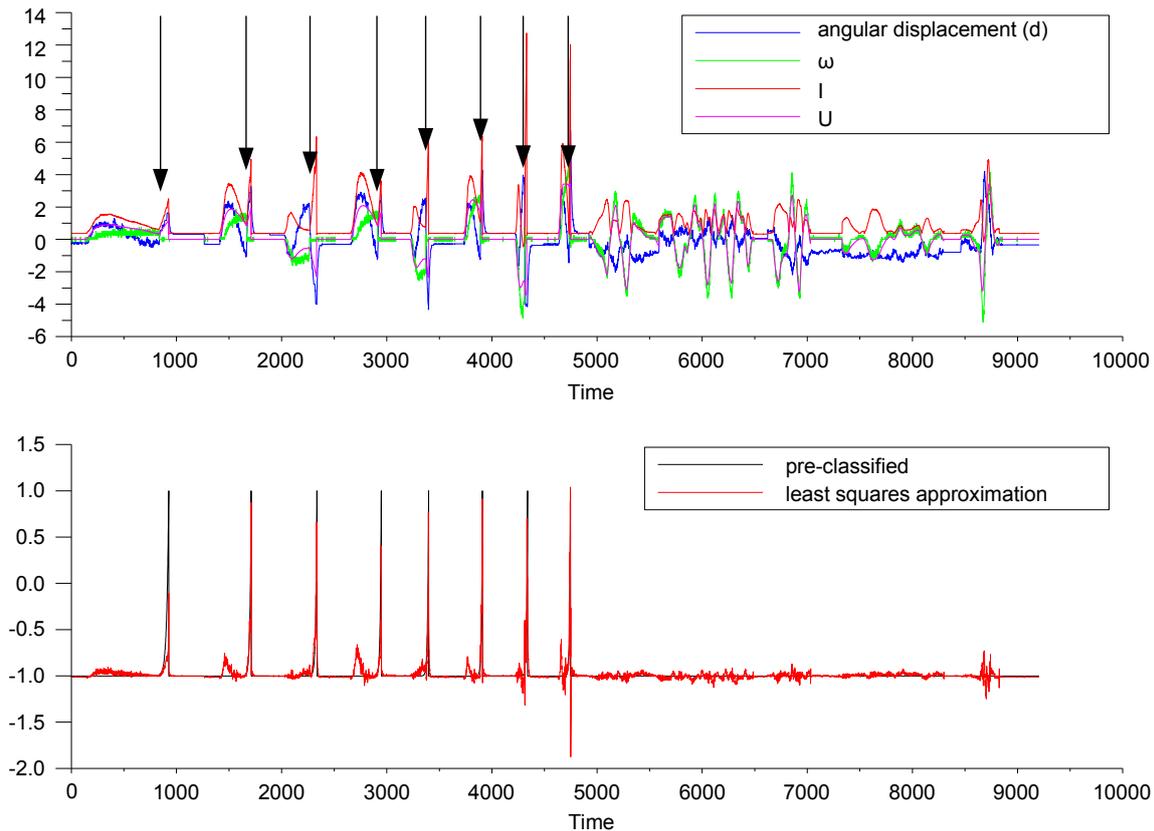


Abbildung 5: Hintereinanderfügung von ausgewählten Versuchen und Approximation von vorgegebenen Kollisionsempulsen mit trainierten Gewichten. Die Pfeile markieren die jeweiligen Kollisionseignisse.

3. Implementation eines Echtzeitverfahrens

3.1. Numerische Berechnung des Trainingsvektors

Für die Bestimmung der Gewichte für verschiedene erweiterte Basen und zur Erstellung der verwendeten Diagramme wurden verschiedene Skripte in der Numeriksoftware Scilab² geschrieben. Die Berechnung der Pseudoinverse kann hier mit der bereits enthaltenen Funktion *pinv* berechnet werden, welche vor allem sinnvoll ist, da sie die Singulärwertzerlegung verwendet und dabei eine Toleranzgrenze anwendet, mit der sehr kleine Singulärwerte auf Null gesetzt werden, so dass die Berechnung damit numerisch stabiler ist als die genannten grundlegenden Vektorumformungen.

²<http://www.scilab.org>

3.2. Neuronale Struktur zur Kollisionsermittlung auf einem Roboter

Die Berechnung der Klassifikation von Echtzeitdaten findet auf der Hardware selbst statt. Die Wahl der Pseudoinverse hat besonders für autonome humanoide Roboter und damit meist begrenzte Hardwareressourcen den positiven Nebeneffekt, dass die Berechnung für unbekannte X mit geringem Rechenaufwand einhergeht, da in jedem Zeitschritt nur noch eine Linearkombination mit festen Gewichten berechnet werden muss. Für den Myon sind in den Abbildungen 6 und 7 grafische Implementationen zur Berechnung der zuvor beschriebenen Klassifikation im Programm *BrainDesigner* gegeben, das für die Programmierung mit neuronalen Netzen von Christian Thiele im Rahmen des Projektes ALEAR entwickelt wird. Die Implementationen können dann auf die einzelnen Steuereinheiten innerhalb des Roboters übertragen und dort ausgeführt werden. Eine automatische Erzeugung der Netzstruktur direkt aus der Lösung der Pseudoinversen ist für weitere Experimente ratsam, da die manuelle Erstellung der Strukturen langwierig werden kann. Es wurden zwei verschieden komplexe Strukturen versucht, um so zusätzlich zu den aufgenommen Versuchsmessungen auch am realen Arm die möglichen Auswirkungen der verschiedenen Basisverkleinerungen beurteilen zu können.

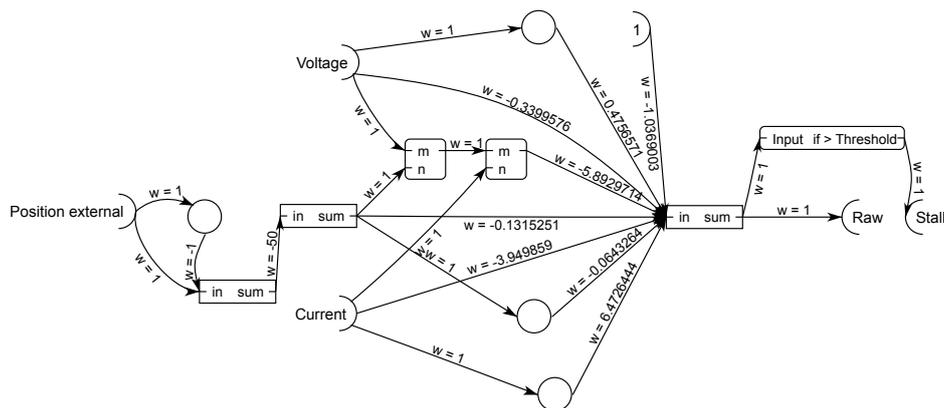


Abbildung 6: Neuronales Netz zur Klassifikation von Echtzeit-Sensordaten mit Acht Koeffizienten aus den Drei Eingangswerten Spannung, Strom und externem Winkel. Es handelt sich um ein einfaches feed-forward-Netz, da nur Vorwärtsverbindungen und keine Rekurrenzen bestehen. Die weißen Kreise sind hier z^{-1} -Elemente (Zeitverzögerung um einen Zeitschritt) mit linearem Übertragungsverhalten, die quadratischen Boxen berechnen eine Multiplikation. Zudem wurden Summationselemente und ein parametrisierter Schwellwertschalter verwendet. Es wird also eine gewichtete Linearkombination der erweiterten Basis mit den im Vorfeld berechneten Gewichten w_i gebildet, die am Ausgang des Moduls den direkten Wert (*Raw*) und die Dekodierung des Klassifikators mittels des Schwellwertschalters (*Stall*) liefert.

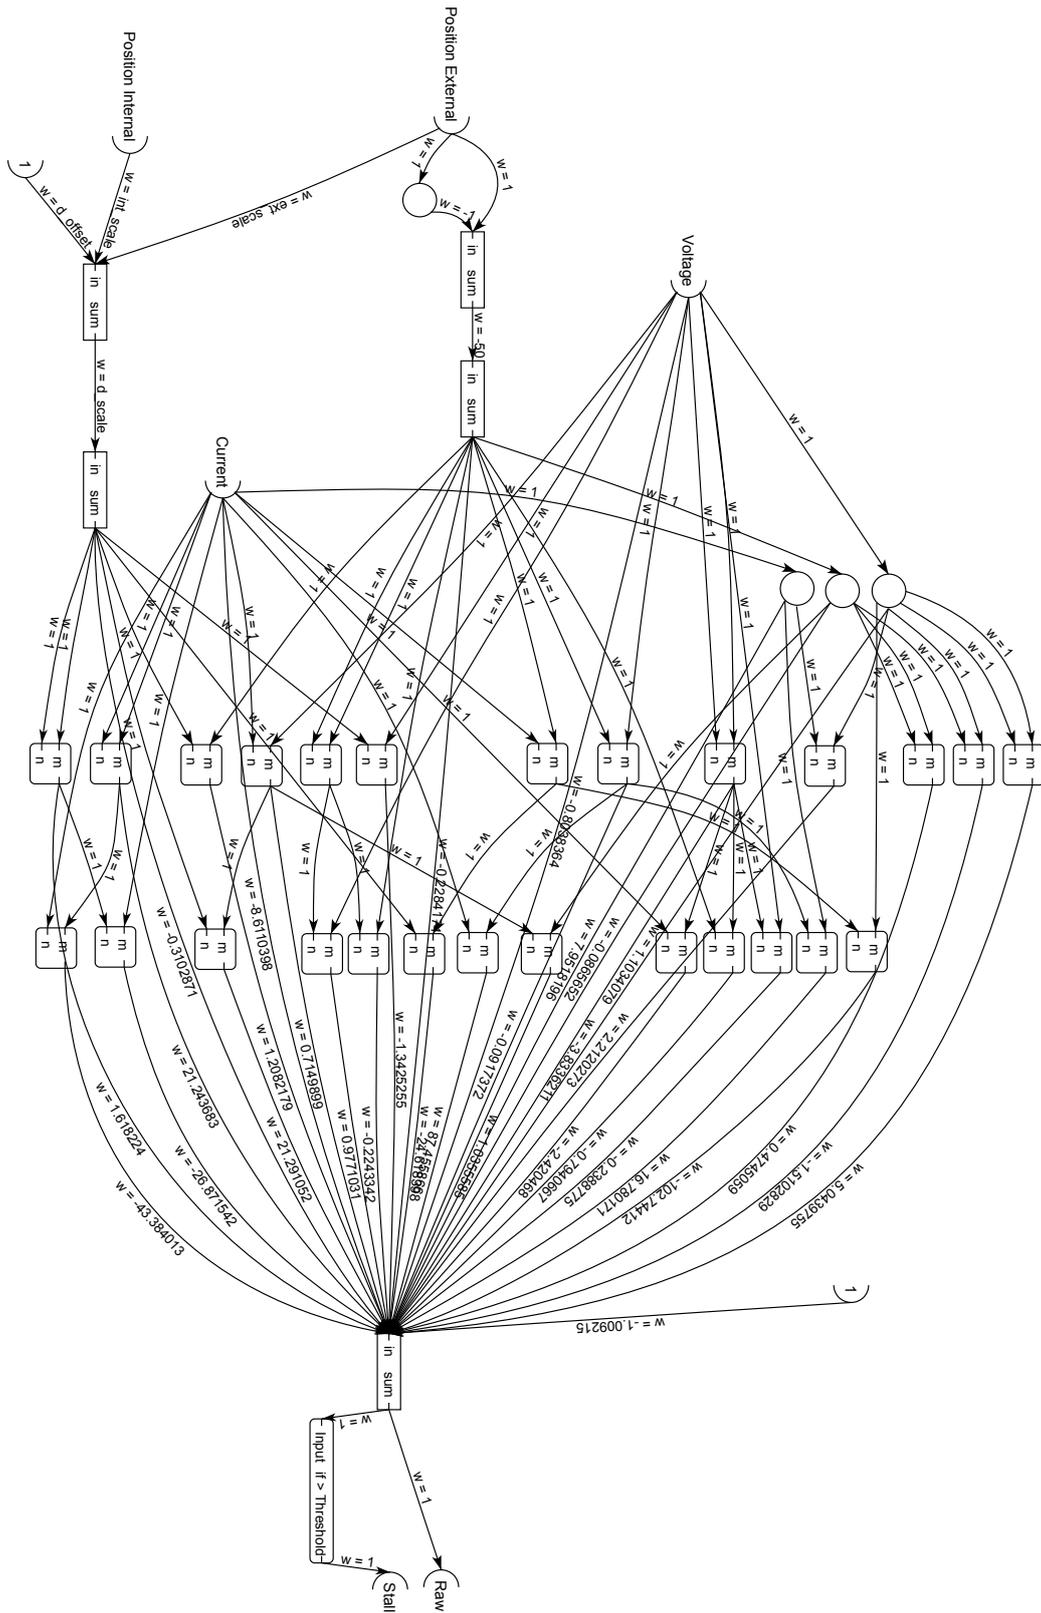


Abbildung 7: Neuronales Netz mit 32 Koeffizienten aus Vier Eingangswerten. Dieses Netz verwendet zusätzlich zu weiteren Monomen den Winkelversatz d .

4. Analyse und Auswertung der praktischen Verwendbarkeit

4.1. Betrachtung einer minimierten Basis

Die auf möglichst wenige Koeffizienten reduzierte Linearkombination

$$y_t = \begin{pmatrix} 2.21 \\ -4.65 \\ -1 \end{pmatrix}^T \cdot \begin{pmatrix} I(t) \\ I(t)U(t)V(t) \\ 1 \end{pmatrix}$$

erlaubt eine noch annähernd funktionierende Klassifikation, die jedoch für die praktische Verwendung zu wenig reaktiv ist (die Gewichte sind nach Abschnitt 2.5 berechnet). Sie zeigt aber, welche grundlegende Funktion die enthaltenen Kenngrößen haben, die der intuitiven Betrachtung aus Abschnitt 2.3 entsprechen. Da $U(t) \cdot V(t)$ und $I(t)$ immer positiv sind, wird in der Linearkombination der Summand $I(t)U(t)V(t)$ bei $V(t) \rightarrow 0$ zu Null, so dass $\vec{y} = 2.21 \cdot I(t) - 1$. Da $I(t)$ maximal Eins ist, geht \vec{y} und damit der Klassifikator gegen Eins falls $I(t)$ ansteigt. Andernfalls heben sich die Summanden $I(t)$ und $I(t)U(t)V(t)$ in etwa auf und $\vec{y} \approx -1$.

Die im kleinen Netz verwendete Linearkombination

$$y_t = \begin{pmatrix} -3.95 \\ -0.34 \\ -0.13 \\ -5.89 \\ 6.47 \\ 0.47 \\ -1.04 \end{pmatrix}^T \cdot \begin{pmatrix} I(t) \\ U(t) \\ V(t) \\ I(t)U(t)V(t) \\ I(t-1) \\ U(t-1) \\ 1 \end{pmatrix}$$

enthält zusätzlich Geschwindigkeit und Spannung und den Wert des jeweils vorherigen Zeitschritts von Strom und Spannung. Die aktuellen Strom- und Spannungswerte werden mit negativem Vorzeichen gewichtet, die vorherigen mit Positivem, so dass durch die Addition innerhalb der Linearkombination der Differenzenquotient gebildet wird. Daher beeinflusst hier also auch die Veränderung der beiden Größen das Ergebnis.

Die Basis des großen Netzes unterscheidet sich vor allem im Einbeziehen des Winkelversatzes, der eine weitere prinzipielle Information liefert. Es wäre auch möglich, den Winkelversatz

nicht explizit vorher zu berechnen. Die Berechnung würde implizit geschehen, jedoch wäre dann die spätere Veränderung von Skalierungsparametern nicht mehr möglich und es würde zu einem Overfitting auf ein bestimmtes Gelenk kommen. Die restlichen Dimensionen sind weitere Monome zweiten und dritten Grades. Eine weitere Betrachtung aller 32 verwendeten Größen wird hier aber aus Komplexitätsgründen ausgelassen. Im folgenden Abschnitt sollen aber die praktischen Auswirkung dieser Unterschiede betrachtet werden.

4.2. Vergleich verschiedener Basen und Gliedmaßen

Zur Untersuchung der Effektivität der beiden neuronalen Implementationen wurden die ursprünglichen Versuche mit einem Arm wiederholt und dabei die Klassifikation vorgenommen. In Abbildung 8 sind bei verschiedenen Geschwindigkeiten in der ersten Spalte Werte für das kleine Netz und in der zweiten Spalte für das größere Netz abgetragen. Es ist zu erkennen, dass bei höherer Geschwindigkeit auch ein höheres Reaktionsvermögen, also ein stärkerer Anstieg der Kurve, vorliegt. Gleichzeitig ist dies auch beim Wechsel zum größeren Netz zu erkennen, was sich mit den Graphen der Klassifikation innerhalb von Scilab deckt. Da das kleine Netz nicht von d abhängig ist, sind während der Beschleunigung im Vergleich zum Großen kaum von -1 verschiedene Werte zu erkennen. Dies deutet darauf hin, dass d die Empfindlichkeit zwar erhöht, die Berechnung dann aber auch empfindlicher auf Beschleunigung reagiert und potentiell mehr ungewollte Werte zu erwarten sind. Das größere Netz erfordert also eine genaue Einstellung der Skalierung und des Offsets für die Berechnung der Winkeldifferenz, damit diese Werte möglichst klein bleiben. Durch normalisieren der relativ zu -1 betrachteten Amplitudenwerte (siehe Abbildung 9) lässt sich unabhängig vom jeweils eingestellten Schwellwert das Reaktionsvermögen besser vergleichen. Der Vorteil des größeren Einstellaufwandes besteht in einer geringen Verbesserung des Zeitverhaltens vom kleinen zum großen neuronalen Netz, besonders bei höheren Geschwindigkeiten, die bei kritischen Anwendungen hilfreich sein kann.

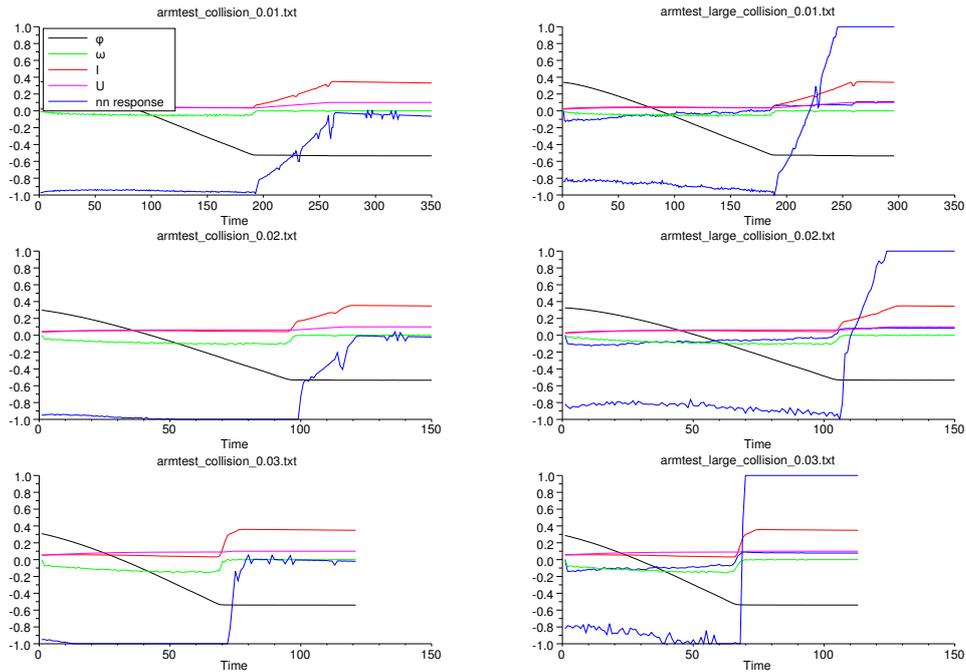


Abbildung 8: Vergleich der Klassifikation von Basen mit Acht Dimensionen (links) und 32 Dimensionen (rechts) an einem Myon-Arm. Die blaue Kurve stellt das Raw-Ausgangssignal des jeweiligen neuronalen Netzes dar.

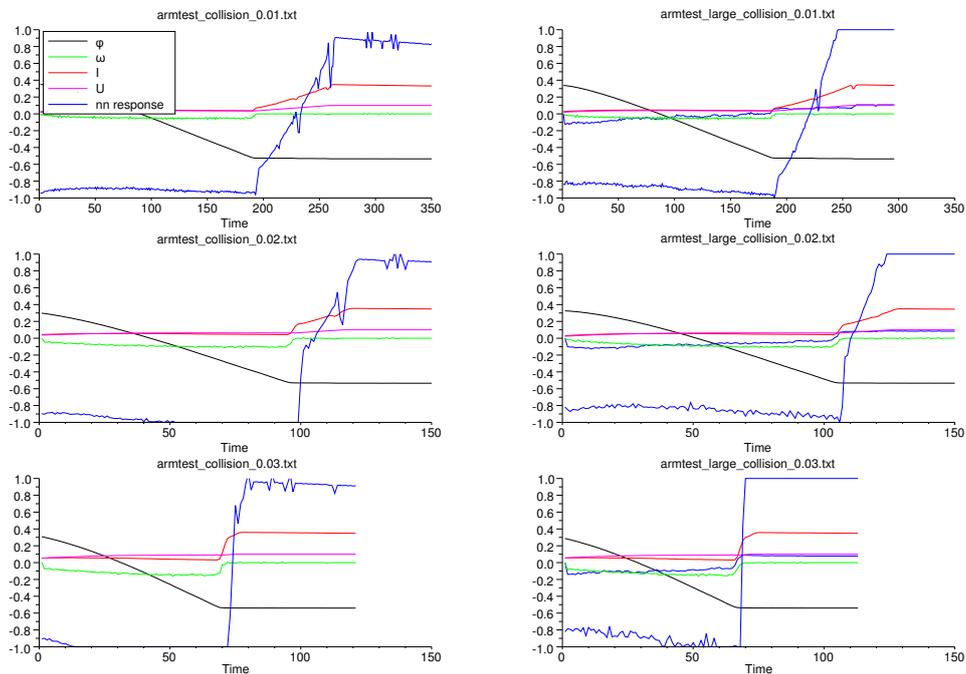


Abbildung 9: Normalisierte Ausgaben der in Abbildung 8 gezeigten Daten.

Im Vergleich dazu wurden die Kollisionsversuche beim Kniegelenk eines Beins in analoger Weise wiederholt, um die Übertragbarkeit zu beurteilen. Auch hier sind analoge Unterschiede zwischen kleinem und großem Netz zu erkennen (siehe Abbildung 10). Im Unterschied zu den Armgelenken werden für das Kniegelenk drei Motoren gleichzeitig angesteuert, um für anspruchsvollere Aufgaben ausreichende Kraftreserven zu haben. Die Elastizität ist hier zudem durch die genannten Federn eine sehr viel stärkere. Diese verändern allerdings im Vergleich zur ausschließlich materialbedingten Elastizität des Armes das Verhalten bei Kollisionen. Insbesondere der Wertebereich der Winkeldifferenz ist damit um eine Größenordnung verschieden. Das große neuronale Netz ist daher wie bereits angedeutet mit einem Faktor für die Winkeldifferenz parametrisiert, der so angepasst werden muss, dass der resultierende Winkelversatz sich im gleichen Wertebereich wie bei einem Arm befindet. Das große Netz kann so auch hier zu verwendbaren Ergebnissen geführt werden. Das kleine Netz liefert weiterhin gute Ergebnisse und reagiert offensichtlich sehr viel robuster auf veränderte Bedingungen.

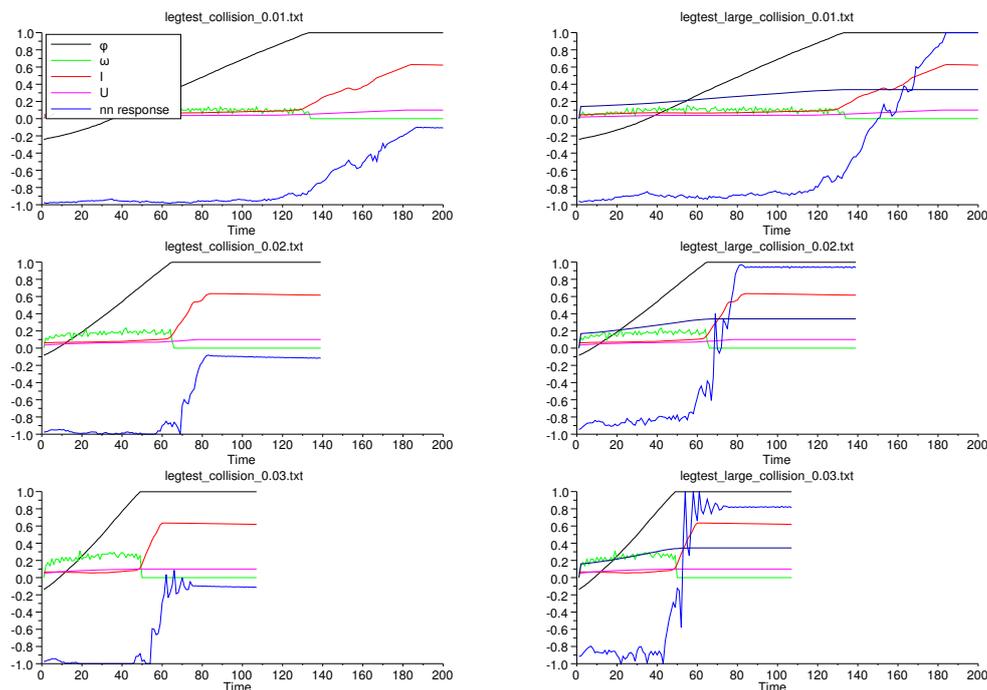


Abbildung 10: Vergleich von Basen mit Acht Dimensionen (links) und 32 Dimensionen (rechts) an einem Myon-Bein.

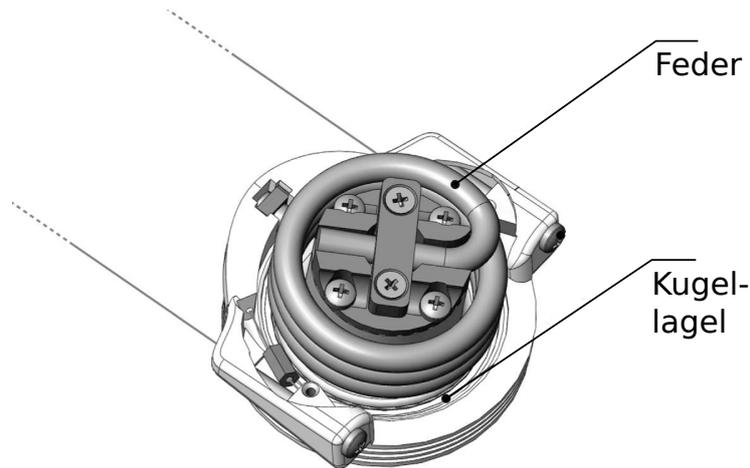


Abbildung 11: Eine am Abtrieb angebrachte Feder, die passiv flexible Gliedmaßen ermöglicht.

Es kann also davon ausgegangen werden, dass sich durch das Verfahren ermittelte Linearkombinationen für unterschiedliche Gelenke eignen, solange diese nicht grundlegend verschieden angesteuert werden und die gegebenenfalls notwendigen Parameter richtig gewählt werden. Andernfalls ist eine erneute Bestimmung von Basis und Gewichten notwendig. Können einzelne Sensordaten nicht mit einfließen, da diese nicht gemessen werden, kann es z. B. beim Zugreifen der Greifhand des Myons schwieriger sein, einen Anschlag zu erkennen. Diese besitzt keinen externen Winkelsensor und zudem eine starke beabsichtigte Federwirkung. Im Experiment konnte erst bei stärkeren Strömen nach vergleichsweise langer Zeit ein Anschlag festgestellt werden. Andererseits ist hier bei der Beschleunigung normalerweise keine große Belastung durch das Eigengewicht gegeben und die Robustheit demgegenüber könnte daher hier geringer sein als z. B. bei einem Arm oder Bein. Es könnte also lohnen, mit weiteren Versuchen eigene Gewichte dafür zu ermitteln um ein empfindlicheres Zugreifen zu ermöglichen.

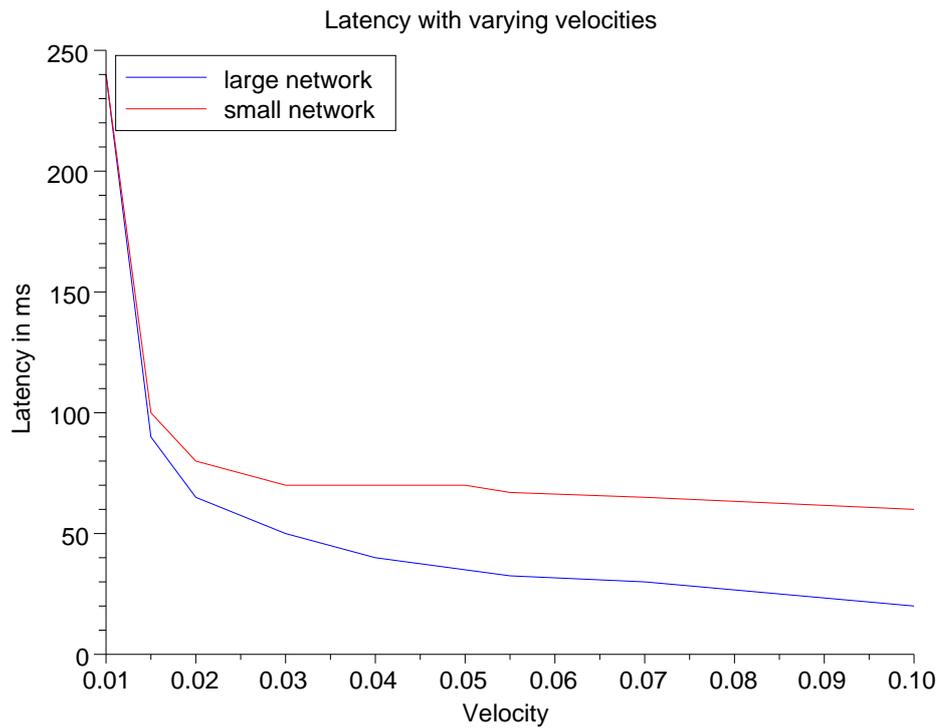


Abbildung 12: Benötigte Zeit, nach der eine Kollision mit einem Schwellwert von -0.5 anhand der Ausgaben der neuronalen Netze erkannt wird, abhängig von der jeweiligen Geschwindigkeit. Das kleine Netz hat nur bei geringer Geschwindigkeit eine Latenz um 200 ms, jedoch bereits bei etwas höheren Geschwindigkeiten eine fast gleichbleibende Verzögerung von 60 - 70 ms.

5. Zusammenfassung und Ausblick

Es wurde ein Verfahren gefunden, das eine robuste Erkennung von Kollisionen eines Myon-Gliedmaßes mit sich selbst oder der Umwelt liefert. Es ist dabei notwendig, den verwendeten Servomotor mit konstant geregelter Geschwindigkeit anzusteuern. Die Verzögerung der Erkennung ist vom angesteuerten Drehmoment abhängig und verhält sich zu diesem wie in Abbildung 12 dargestellt. Insofern die Vorteile der Verwendung der Implementation mit vielen Parametern für eine weitere Anwendung gewünscht sind, ist es nötig, die entsprechenden Winkelparameter der verwendeten Hardware zu ermitteln (siehe dazu Anhang A). Driftfehler der Sensoren und wechseln der Hardware werden dadurch jedoch besonders zum Problem. Alternativ ist die Variante ohne Winkelversatz von diesen Problemen relativ unbetroffen und kann direkt verwendet werden. Zudem ist die gleichförmigere und damit vorhersagbare Zeitverzögerung für manche Anwendungen vorteilhaft.

Es bleibt zu untersuchen, welche Anwendungen sinnvoll sind und inwiefern Verbesserungen notwendig und möglich sind. Insbesondere Kollisionen mit beweglichen oder leichten Gegenständen wie z. B. eine Wasserflasche führen bei kräftigen Motoren nicht zu dem für das Verfahren nötigen Geschwindigkeitseinbruch, der eine Klassifikation erlaubt. Denkbar sind aber dagegen die Verwendung in Kombination mit einem Lernverfahren, das den Bewegungsspielraum eines Gliedmaßes erkundet, um einmal festgestellte Kollisionen in einem gewissen Bereich nicht zu wiederholen. Eine bestimmte Winkelkonfiguration kann bei einer Kollision gelernt werden und danach die Ansteuerung in diesem Bereich inhibieren.

Anhang A Anpassen von Parametern der neuronalen Netze an spezifische Hardware

Die Ermittlung der Parameter ext_scale , int_scale , d_offset und d_scale soll hier kurz erläutert werden. Die Wertebereich der Winkelsensoren sollen auf das Intervall $[0, 1]$ abgebildet werden. Dafür müssen für das verwendete Gelenk die maximalen und minimalen Werte an den physikalischen Anschlägen ermittelt werden. Der Skalierungsfaktor ist dann $\frac{1}{max-min}$. d_scale und d_offset sollen so eingestellt sein, dass der resultierende Winkelversatz sich um Null und etwa im Bereich von -0.3 bis $+0.3$ bewegt. Wie zuvor genannt, wurde der Parameter d_scale zur Anpassung an andere Federeigenschaften hinzugefügt, so dass für einen Arm der ursprüngliche Wert von Zehn sinnvoll ist. Bei einem Myon-Bein ist ein größerer Winkelversatz durch die größere Federwirkung vorhanden, daher kann der Wert auf Eins verringert werden. Der Schwellwert für die Unterscheidung von Kollision von freier Bewegung ($threshold$) sollte etwas größer als die maximal festgestellten Raw-Werte bei freier Bewegung mit möglichen Behinderungen und zu tolerierenden Gegenkräften eingestellt werden.

Anhang B Weitere Messdaten

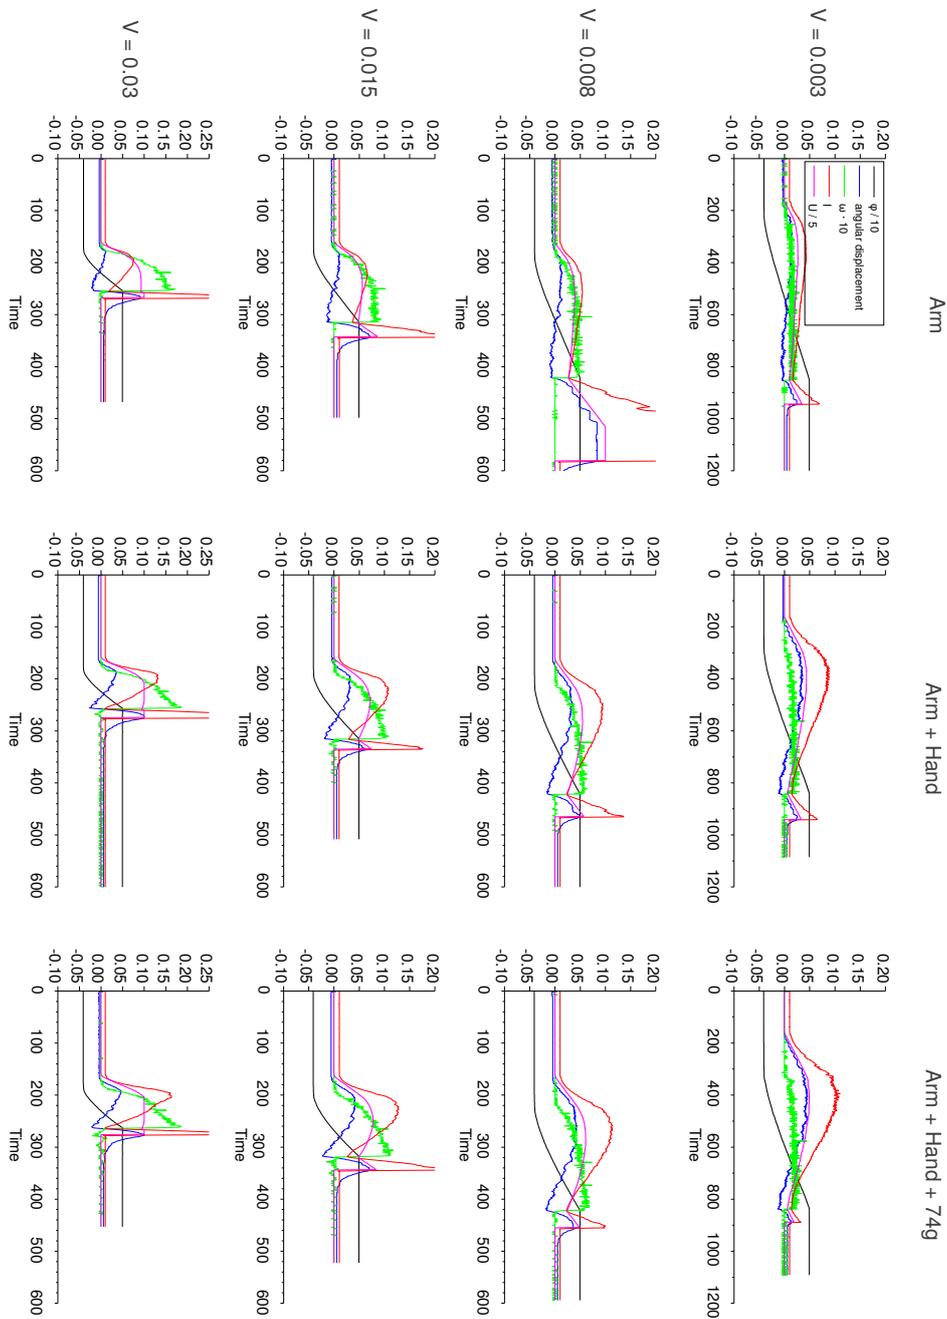


Abbildung 13: Messdaten der Versuche in positiver Richtung (entgegen der Gravitation). Einige Werte sind für eine bessere Darstellung wie in der Legende angegeben skaliert.

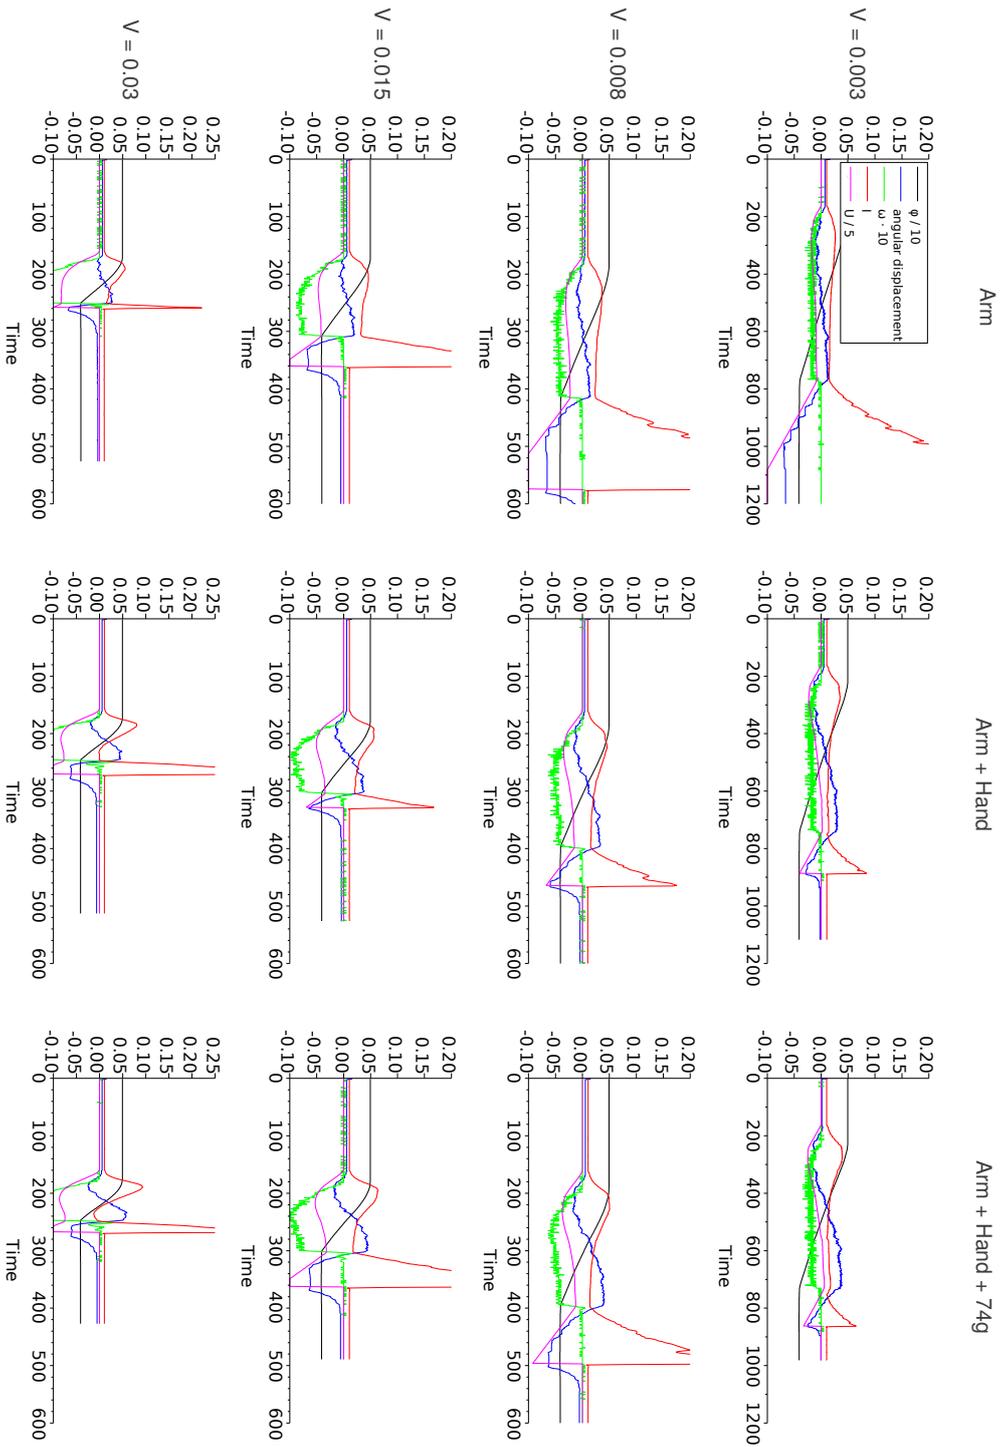


Abbildung 14: Messdaten der Versuche in negativer Richtung (mit der Gravitation).

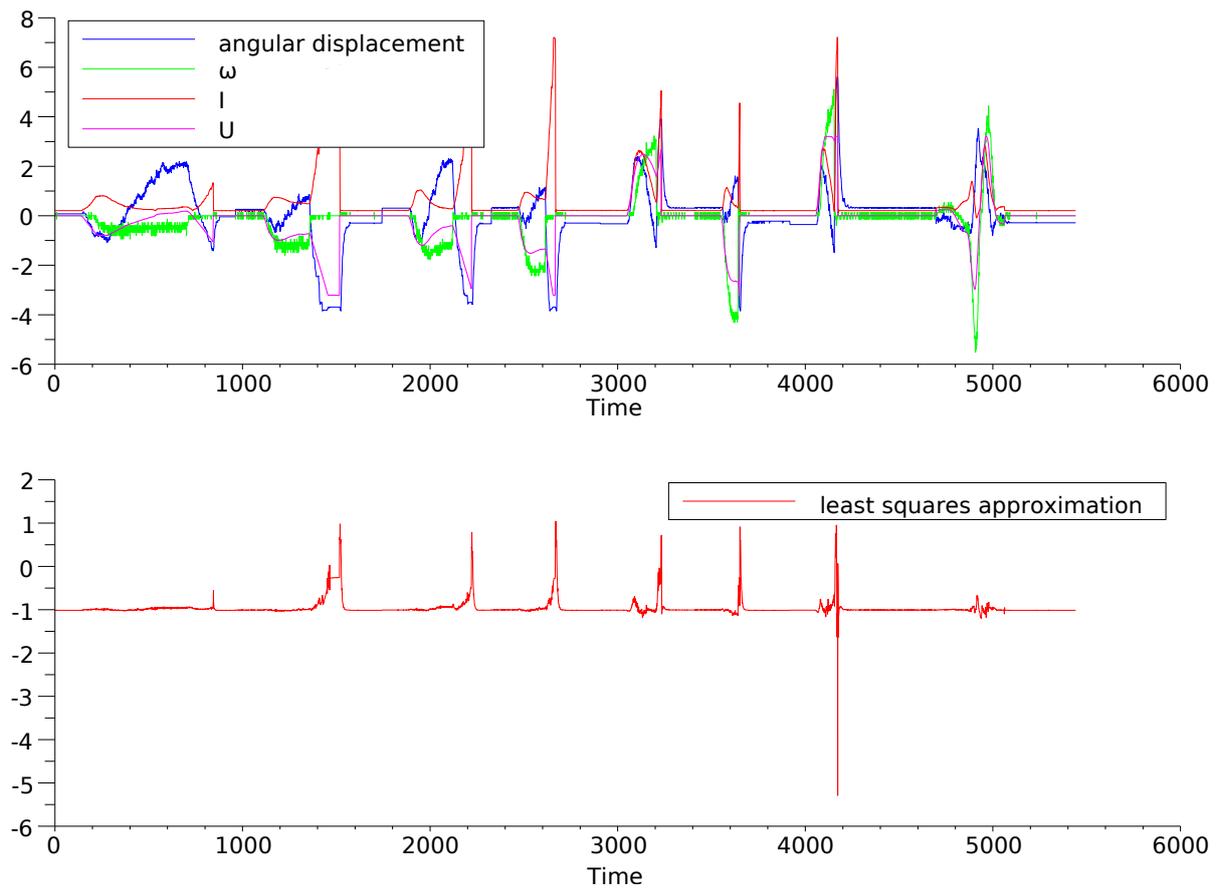


Abbildung 15: Berechnung der Klassifikation für Messdaten, mit denen nicht trainiert wurde. Der letzte Versuch ist keine Kollision, die Klassifikation ist daher dort nahe null. Die Klassifikation des ersten Versuches hat allerdings einen ähnlich großen Ausschlag, da der Anstieg des Stroms verglichen mit den übrigen Versuchen relativ gering ist.

Literatur

- [Hild et al. 2011] M. Hild, T. Siedel, C. Benckendorff, M. Kubisch und C. Thiele: “Myon: Concepts and Design of a Modular Humanoid Robot Which Can Be Reassembled During Runtime”, 2011.
- [Migliore et al. 2010] S. A. Migliore, L. H. Ting und S. P. DeWeerth: “Passive joint stiffness in the hip and knee increases the energy efficiency of leg swinging, in Autonomous Robots”, 2010.
- [Quinlan et al. 2003] M. J. Quinlan, C. L. Murch, R. H. Middleton und S. K. Chalup: “Traction Monitoring for Collision Detection with Legged Robots”, RoboCup 2003 Symposium, 2003.
- [Quinlan et al. 2004] M. J. Quinlan, S. K. Chalup und R. H. Middleton: “Application of SVMs for Colour Classification and Collision Detection with AIBO Robots”, Advances in Neural Information Processing Systems (NIPS’2003), 2004.
- [Hild et al. 2011] M. Hild, T. Siedel, C. Benckendorff, C. Thiele und M. Spranger: “Integrating high level cognitive systems with sensorimotor control”, 2011.
- [Moore 1920] E. H. Moore: “On the reciprocal of the general algebraic matrix”. Bulletin of the American Mathematical Society 26: 394–395, 1920.
- [Wolberg 2006] J.R. Wolberg: “Data analysis using the method of least squares”, S.65., Springer 2006.
- [Markov 1912] A. A. Markoff: “Wahrscheinlichkeitsrechnung”, 2. Auflage, Cornell University Library, 1912.

Erklärung

Hiermit erkläre ich, die vorliegende Studienarbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel verwendet zu haben.

Berlin, den 12. Mai 2011

Stefan Bethge