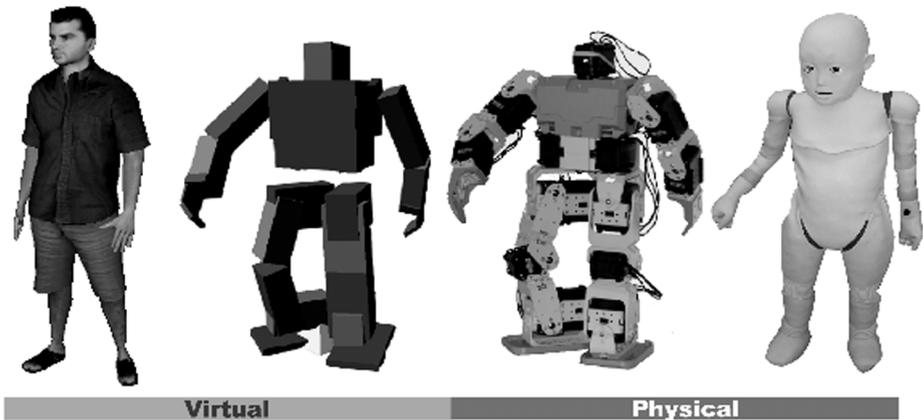


Imitation Learning of Motor Skills for Synthetic Humanoids

Heni Ben Amor

Institut für Informatik
Technische Universität Bergakademie Freiberg
amor@tu-freiberg.de



Abstract:In der hier besprochenen Arbeit werden Verfahren vorgestellt, die eine adaptive Bewegungsgenerierung für synthetische Humanoide ermöglichen. Die Verfahren basieren auf dem Prinzip des Imitationslernens: Bewegungen werden zuerst aufgezeichnet und dann mithilfe einer neuartigen Methode des maschinellen Lernens, dem Probabilistic Low-Dimensional Posture Model, in generative Modelle umgewandelt. Die gelernten Modelle können daraufhin zur Generierung von neuen Bewegungen zur Laufzeit genutzt werden. Die Verfahren werden an verschiedenen virtuellen und robotischen Humanoiden getestet und ausgewertet.

1 Einleitung

Die hier besprochene Arbeit befasst sich mit der Entwicklung und Anwendung adaptiver Methoden zur Bewegungsgenerierung für synthetische Humanoide, wie virtuelle Menschen oder androide Roboter. Hierzu wird ein neues Verfahren zum Imitationslernen vorgestellt, welches basierend auf einem oder mehreren Beispielbewegungen ein kompaktes,

statistisches Modell konstruiert. Dieses kann dazu verwendet werden, verschiedene Varianten der demonstrierten Bewegung zu erzeugen. Im Vordergrund steht dabei die Anpassung der Bewegung an dynamische Umgebungen und menschliche Interaktionspartner. Die Anwendung auf Problemstellungen in der Computeranimation und der Robotik zeigt, dass selbst komplexe Verhaltensmuster, wie das Greifen und Manipulieren von Objekten auf intuitive Weise realisiert werden können. Experimente mit einem fortschrittlichen androiden Roboter belegen zudem, dass der Ansatz zur Verbesserung der physischen Mensch-Roboter-Interaktion und -Kooperation genutzt werden kann.

2 Aufgabenstellung

Die Fragestellung, welcher in dieser Arbeit nachgegangen wurde, kann wie folgt zusammengefasst werden:

Wie kann man synthetischen Humanoiden auf intuitive und natürliche Weise motorische Fähigkeiten lehren, so dass diese daraufhin in unterschiedlichen Situationen und Umgebungen reproduziert werden können?

Die obige Fragestellung kann weiterhin in folgende Teilfragen zerlegt werden:

- Wie kann man motorische Fähigkeiten mit einem Minimum an Programmieraufwand spezifizieren?
- Ist es möglich einen generellen Ansatz zur Spezifikation von motorischen Fähigkeiten zu entwickeln, welcher sowohl für virtuelle Agenten als auch für (physisch präsente) Roboter anwendbar ist?
- Wie müssen menschliche Bewegungen und Posturen repräsentiert werden, um diesen Prozess zu unterstützen?
- Wie können trainierte Bewegungen auf neue Situationen angepasst werden?

3 Methodik

In der Arbeit wird ein Ansatz vorgestellt, welcher im Überlappungsbereich zwischen Künstlicher Intelligenz, Robotik, Computer Animation und Mensch-Maschine Schnittstellen ist. Insbesondere beruht der Ansatz auf dem Konzept der Imitation: Verhalten werden gelernt, in dem menschliche Bewegungen beobachtet und modelliert werden. Der Ablauf ist in Abbildung 1 dargestellt. Zuerst wird eine Demonstration der zu lernenden Bewegung mithilfe moderner Sensortechnologien aufgezeichnet. Anders als bei bisherigen Animationsstechniken, werden die aufgezeichneten Daten nicht direkt gespeichert, sondern zuerst

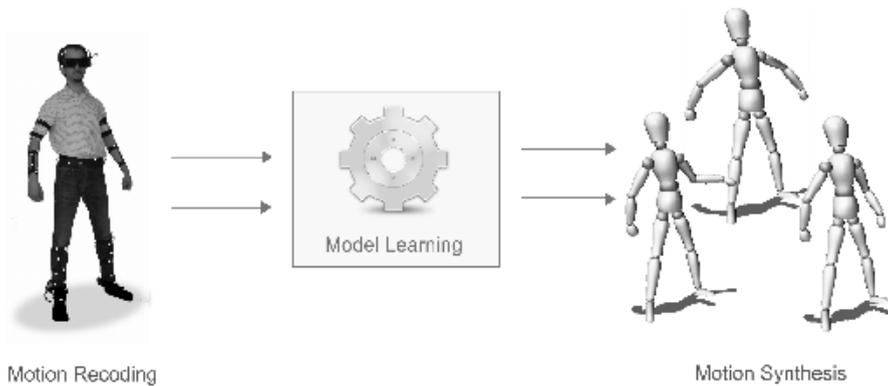


Abbildung 1: Überblick über das Verfahren zum Imitationslernen: Bewegungen werden ausgezeichnet und in mathematische Modelle überführt. Diese können daraufhin dazu verwendet werden beliebige neue und gleichzeitig ähnliche Bewegungen zu erzeugen. Die Generierung neuer Bewegungen ist dabei abhängig von der aktuellen Situation.

mithilfe mathematischer Methoden verarbeitet. Zu diesem Zweck wird ein neues statistisches Modell namens *Probabilistic Low-Dimensional Posture Model* (PLDPM) vorgestellt. Ein gelerntes Modell kann daraufhin verwendet werden, um eine auf die aktuelle Situation angepasste Bewegung zu generieren. Im Kern des Ansatzes stehen Verfahren zur Dimensionsreduktion und zum maschinellen Lernen.

4 Probabilistic Low-Dimensional Posture Model

Die PLDPM-Algorithmus ist ein unüberwachtes Lernverfahren zur Erzeugung einer kompakten Beschreibung der kinematischen und anatomischen Parameter die einem motorischen Verhalten zugrunde liegen. Dabei wird der Umstand ausgenutzt, dass natürliche Bewegung oftmals durch die Kombination einer kleinen Menge von Komponenten erzeugt werden kann. So wurde in [SFS98] mithilfe der PCA gezeigt, dass zwei Hauptkomponenten ausreichen um mehr als achtzig Prozent der Varianz in Handbewegungen abzudecken. Alexandrov und Kollegen zeigten in [AFM98], dass die erste Hauptkomponente von aufgezeichneten Rumpfbewegungen bereits mehr als 80% der inhärenten Varianz erfasst. Diese und andere Ergebnisse in der Literatur zeigen, dass Techniken der Dimensionsreduktion erfolgreich zur kompakten Repräsentation von Bewegungen eingesetzt werden können.

Aufbauend auf diesen Erkenntnissen, verwendet der Algorithmus zur Berechnung einer PLDPM Dimensionsreduktionstechniken zur automatischen Extraktion eines minimalen Satzes von Hauptkomponenten aus aufgezeichneten kinematischen Daten. Aus diesen Berechnungen ergibt sich ein *niedrig-dimensionaler Posturraum*: ein mathematischer Raum, in dem jeder Punkt eine Postur darstellt welche typisch für das modellierte Verhalten ist. Zusätzlich werden in dem PLDPM auch anatomische Einschränkungen gespeichert. Diese

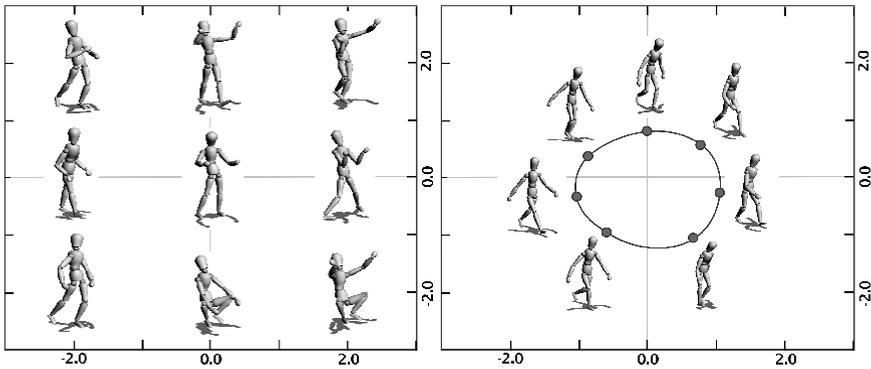


Abbildung 2: Links: Die Visualisierung eines niedrig-dimensionalen Raumes für 'box-lifting'. Rechts: Die Visualisierung eines niedrig-dimensionalen Raumes für 'walking'. Die Trajektorie durch sieben Punkte spezifiziert eine Gehbewegung.

gewährleisten, dass alle synthetisierten Körperhaltungen und Animationen natürlich und realistisch wirken. Um solche Beschränkungen aus den aufgezeichneten Daten zu extrahieren werden statistische Methoden verwendet. Daher ist kein Vorwissen über die Mechanik des modellierten Humanoiden notwendig.

In Abbildung 2 (links) sehen wir die Darstellung eines extrahierten niedrig-dimensionalen Raumes. Wie bereits erwähnt repräsentiert jeder Raum eine Postur. In Abbildung 2 (rechts) sehen wir einen niedrig-dimensionalen Raum für Gehbewegungen. Hier sehen wir, dass mehrere Punkte miteinander zu einer Trajektorie verbunden werden können, um eine Bewegung zu spezifizieren. Daraus lässt sich erkennen, dass die Generierung einer Bewegung mithilfe von PLDPMs einer Suche im niedrigdimensionalen Posturraum gleichkommt: Gesucht wird eine Trajektorie im Raum, die eine natürliche Bewegung erzeugt, welche gleichzeitig die Beschränkungen der Umgebung berücksichtigt.

Der Ansatz kann u.a. dazu verwendet werden, um Griffbewegungen und Gehbewegungen zu lernen.

5 Synthese von Griffen

Im Folgenden werden wir das Problem der Erzeugung von natürlichen Griffen für synthetische Humanoide betrachten. Gegeben einer geometrischen Beschreibung eines (zu greifenden) Zielobjektes, wird eine Handpostur gesucht, die zu einem natürlichen und stabilen Griff korrespondiert. Eine Schwierigkeit bei der Synthese von Griffen ist die Tatsache, dass Objekte auf eine Vielzahl von möglichen Weisen gegriffen werden können.

In Abbildung 3 sehen wir, wie der eingeführte Ansatz zur Imitation von Griffen verwendet werden kann. Zuerst werden mithilfe eines Fingertrackers Greifbewegungen aufgezeichnet. Die aufgezeichneten Griffe werden in eine PLDPM überführt. Jeder Punkt im PLDPM stellt einen Griff dar. Einige der Griffe im PLDPM sind jedoch anatomisch nicht plausi-

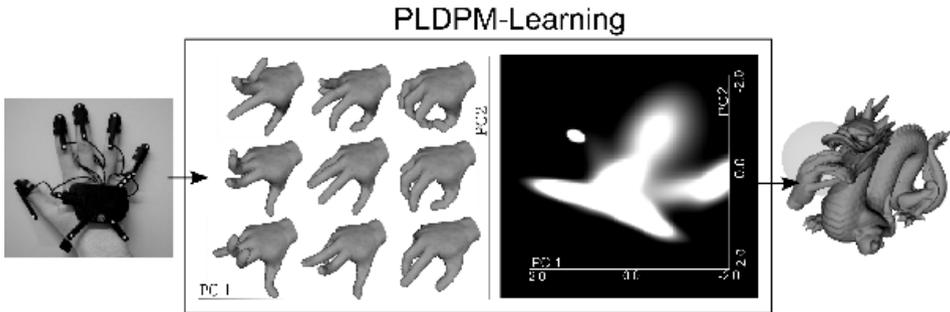


Abbildung 3: Der Ablauf des Griffsynthese Algorithmus: aufgezeichnete Bewegungen werden in ein PLDPM überführt. Mithilfe von Optimierungsalgorithmen werden draufhin neue Bewegungen generiert. Dabei wird mit Optimierungstechniken im Posturraum nach einem stabilen Griff gesucht.

bel und wirken unnatürlich. Hier kommen statistische Methoden zum Einsatz, um einzuschätzen wie realistisch ein Griff ist. Hierzu wird auf der Menge der trainierten Griffe eine Wahrscheinlichkeitsdichtefunktion (PDF) berechnet. Die PDF liefert für jeden Punkt im Posturraum die dazugehörige Wahrscheinlichkeit.

Weiterhin wird für die Synthese von Griffen eine Metrik verwendet, mit welcher für jeden Griff eingeschätzt werden kann, wie stabil dieser im Bezug auf das betrachtete Objekt ist. Die PDF und die Stabilitätsmetrik werden kombiniert, um die Natürlichkeit und die Stabilität des aktuell betrachteten Punktes im Posturraum zu berechnen. Diese Information wird als Optimierungskriterium verwendet, so dass ein iteratives Optimierungsverfahren nach dem idealen Griff suchen kann.

6 Synthese von Ganzkörperbewegungen

6.1 Gehbewegungen für virtuelle Menschen

Der eingeführte Ansatz kann auch zur Synthese von Ganzkörperbewegungen verwendet werden. Der hauptsächliche Unterschied zu dem eingeführten Griffsynthese Beispiel ist die Sensortechnologie, mit welcher die kinematischen Daten aufgezeichnet werden. Wie wir in Abbildung 4 sehen, können Ganzkörperbewegungen bspw. durch Motion-Capturing Techniken aufgezeichnet werden.

Die aufgezeichneten Körperposturen werden dann ähnlich wie bei dem Griffbeispiel in ein PLDPM überführt. Erzeugt man in dem dazugehörigen Posturraum eine Trajektorie, so ergibt sich daraus eine Gehbewegung. Verschiedene Trajektorien korrespondieren dabei mit verschiedenen Gehbewegungen. Durch die Modulation der Trajektorie im Posturraum kann daher z.B. die Gangart und die Ganggeschwindigkeit variiert werden. Auf diese Weise ist es z.B. möglich eine Gehbewegung zu erzeugen, welche aktuellen Hindernissen in der Umgebung ausweicht. Während die bisherigen Beispiele sich hauptsächlich auf Daten

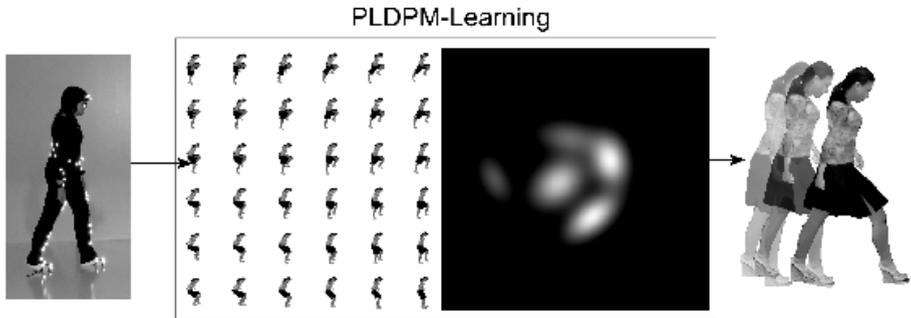


Abbildung 4: Imitationslernen einer Gehbewegung aus Motion Capture Daten. Zuerst wird die Bewegung aufgezeichnet. Ein Proband trägt Marker am Körper, die von speziellen Kameras erkannt werden. Die aufgezeichneten Daten werden daraufhin durch ein PLDPM verarbeitet. Aus dem Modell wird daraufhin eine neue Gehbewegung erzeugt, wobei Gangart und Geschwindigkeit variiert werden können.

aus Tracking und Motion Capturing Techniken gestützt haben, zeigt das folgende Beispiel, dass auch andere Daten zum Training verwendet werden können.

6.2 Programming-by-Demonstration für Roboter

Die Programmierung von Bewegungen für Roboter ist ein komplexer Prozess, welcher zudem Expertenwissen in einigen Wissenschaftsbereichen wie z.B. KI, Biomechanik oder Robotik voraussetzt. Der hier vorgestellte Imitationslernansatz kann jedoch dazu verwendet werden, den obigen Prozess intuitiver zu gestalten und damit zu erleichtern. Die Grundidee beruht dabei auf der Beobachtung, dass Kleinkinder und Jugendliche beim Erlernen von motorischen Fähigkeiten oftmals physisch von ihren Eltern oder einem Trainer unterstützt werden. Diese Beobachtung kann aufgegriffen und auf Roboter angewandt werden. In Abbildung 5 sehen wir wie dies geschehen kann.



Abbildung 5: Ein Proband demonstriert einem Roboter eine Aufstehbewegung indem er dessen Gelenke bewegt.

Ein Proband zeigt einem Roboter eine Aufstehbewegung, indem er dessen Gelenke be-

wegt. Während dieses Prozesses werden die Posturen des Roboters (die Konfiguration von der Motoren) kontinuierlich aufgezeichnet und abgespeichert. Theoretisch ist es jetzt möglich die aufgezeichneten Daten wieder abzuspielen, damit der Roboter die Bewegung selbstständig durchführt. Dies gelingt jedoch in den meisten Fällen nicht, da die stabilisierenden Kräfte des Probanden fehlen. Daraus kann geschlossen werden, dass die demonstrierte Bewegung verändert werden muss, damit der Roboter diese selbstständig abspielen kann. Dieser Prozess kann durch den PLDPM-Algorithmus unterstützt werden. Abbildung 6 visualisiert diesen als ‘Kinesthetic Bootstrapping’ bezeichneten Prozess.

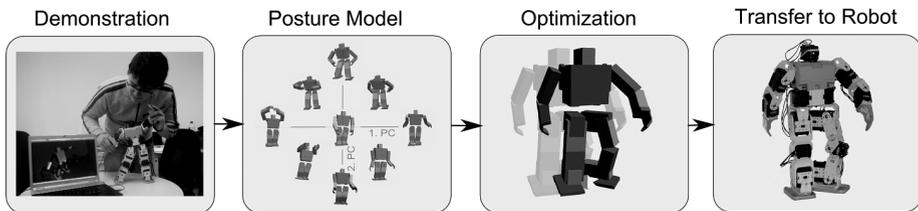


Abbildung 6: Überblick über Kinesthetic Bootstrapping: Kinesthetisch demonstrierte Bewegungen werden aufgezeichnet und ein PLDPM wird gelernt. Ein Simulator wird dann verwendet, um die Bewegung auf die physikalischen Parameter des Roboters anzupassen. Das Ergebnis wird dann auf dem Roboter abgespielt.

Aus den aufgezeichneten Daten wird zuerst ein PLDPM gelernt. Dieses wird daraufhin verwendet, um eine stabile Variante des demonstrierten Verhalten zu finden. Hierzu wird die Bewegung innerhalb eines Simulators optimiert. Im Gegensatz zu der Optimierung mit einem echten Roboter, kann die Optimierung in einem Simulator viel schneller erfolgen. Zudem wird dadurch garantiert, dass der Roboter beim Optimierungsprozess nicht beeinträchtigt wird. Nachdem eine optimale Bewegung im Simulator gefunden wurde, kann diese auf den echten Roboter übertragen und abgespielt werden.

Das Kinesthetic Bootstrapping Verfahren erlaubt es Robotern auf intuitive Weise neue Bewegungen beizubringen. Gleichzeitig beruht es nicht auf teuren Motion Capturing Techniken. Im Unterschied zu Motion Capture basierten Techniken, kann es zudem an jedem ort durchgeführt werden, an dem sich der Roboter befindet.

7 Physical Interaction Learning

Während es in den bisherigen Beispielen eine strikte Trennung von Demonstration und Reproduktion eines Verhaltens gab, zeigt das folgende Beispiel wie diese Trennung aufgehoben werden kann. Dies ist insbesondere in der Mensch-Roboter Interaktion hilfreich.

Der hier besprochene Physical Interaction Learning (PIL) Ansatz beruht im Kern auf dem PLDPM-Algorithmus. Im Unterschied zu Kinesthetic Bootstrapping, lernt der Roboter beim PIL *während* er mit dem Menschen interagiert. Hauptsächlich soll der Roboter lernen

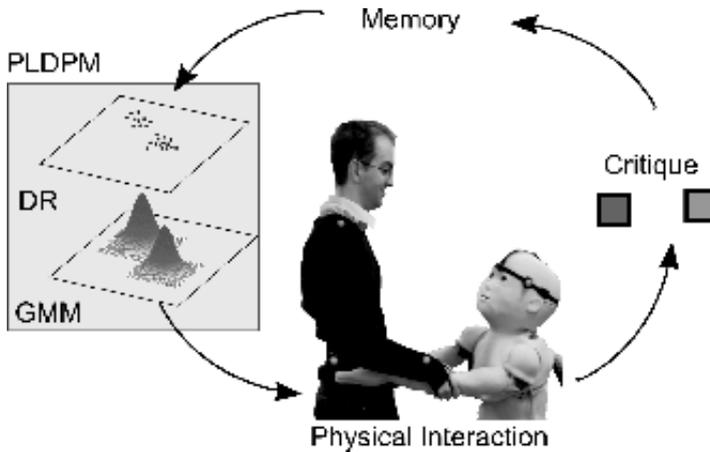


Abbildung 7: Überblick über Physical Interaction Learning: Nach einer physikalischen Interaktion beurteilt der Mensch ob die Interaktion erfolgreich war oder nicht. Diese Information wird abgespeichert und zum Erlernen von mehreren PLDPMs verwendet, welche wiederum den Roboter in der nächsten Interaktion steuern.

sich auf den Menschen und dessen Timing anzupassen. Abbildung 7 zeigt diesen Prozess. Der Mensch interagiert mit dem Roboter und bewertet danach, ob die Interaktion erfolgreich war oder nicht. Diese Information wird daraufhin gespeichert und zum Trainieren mehrerer PLDPMs verwendet. Diese wiederum steuern die Bewegung des Roboters in der nächsten Interaktion. Dieser Kreislauf verbessert zunehmend die Qualität der Interaktion zwischen Mensch und Roboter. Um dies zu testen wurde ein Experiment mit mehreren Probanden durchgeführt, in welchem die Probanden einem androiden Roboter beim Aufstehen assistieren sollen. Damit die Interaktion gelingt und für den Menschen mit einem minimalen Kraftaufwand verbunden ist, muss der Android den zeitlichen Ablauf seiner Bewegung auf den Menschen anpassen. Dies geschieht wie beschrieben mithilfe des Physical Interaction Learning. In Abbildung 8 sehen wir Beispielinteraktionen vor (oben) und nach (unten) dem Lernen. Die Experimente die in diesem Rahmen durchgeführt wurden, gehören weltweit zu den ersten Experimenten in denen enger körperlicher Kontakt zwischen Menschen und Androiden untersucht wurde.

8 Action Capture

Action Capture ist eine VR-basierte Methode zur Imitation von aufgezeichneten Aktionssequenzen durch virtuelle Menschen, welches im Kern auf PLDPMs basiert. Ähnlich wie bei Motion Capture, werden Bewegungen des Benutzers mithilfe moderner Sensortechnologie aufgezeichnet. Im Unterschied zu der letztgenannten Technik werden bei Action Capture jedoch auch Interaktionen zwischen dem Benutzer und der Umgebung aufgezeichnet. Ein motivierendes Beispiel für Action Capture ist das *Virtuelle Prototyping*.

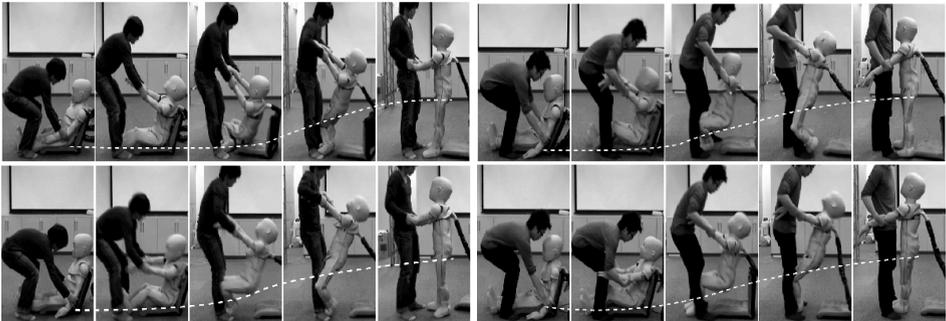


Abbildung 8: Darstellung der ersten (oben) und letzten (unten) Interaktion beim assistierten Aufstehen.

Beim Virtuellen Prototyping wird ein technisches Produkt zuerst in einer virtuellen Umgebung simuliert und evaluiert. Diese Evaluation wird in der Regel von einem Menschen mithilfe von Datenhandschuhen und Trackern durchgeführt. So kann bspw. früh erkannt werden, ob in einem Autoprototypen alle Knöpfe für den Fahrer erreichbar sind. Action Capture erlaubt es eine solche Evaluation aufzuzeichnen und als eine Aktionssequenz zu speichern. Auf diese Weise können die Aktionen danach von virtuellen Menschen mit verschiedenen Proportionen imitiert werden (siehe Abbildung 9). Dies resultiert in einer automatisierten und somit objektiveren Evaluation. Zudem führt dies zu deutlichen Zeiterparnissen beim Prototyping.



VR User



Virtual Human

Abbildung 9: Links: Ein VR Benutzer evaluiert einen Autoprototypen. Rechts: Die Aktionen des Benutzers werden von einem virtuellen Menschen imitiert.

9 Zusammenfassung

Die hier besprochene Arbeit behandelt die Frage, wie man synthetischen Humanoiden motorische Fähigkeiten lehren kann. Ein allgemeiner Ansatz, der auf Imitationslernen basiert,

wurde vorgestellt und auf einer Reihe von synthetischen Humanoiden (virtuelle Menschen, kleine Humanoide Roboter, Androide Roboter) getestet. Der Ansatz ermöglicht eine intuitive und natürliche Spezifikation motorischer Fähigkeiten, ohne die Notwendigkeit für Expertenwissen. Es konnte gezeigt werden, dass mit diesem Ansatz verschiedene wichtige Probleme in der Robotik und Computer-Animation gelöst werden können, einschließlich der Synthese von natürlichen Griffen, der Synthese von Gehbewegungen und die physische Interaktion zwischen Mensch und Roboter.

Literatur

- [AFM98] A. Alexandrov, A. Frolov und J. Massion. Axial synergies during human upper trunk bending. *Exp. Brain Res.*, 118(2), 1998.
- [SFS98] M. Santello, M. Flanders und J. F. Soetching. Postural Hand Synergies for Tool Use. *The Journal of Neuroscience*, 18(23):10105–10115, 1998.



Heni Ben Amor wurde am 1. Februar 1982 in Dernbach geboren. Nach dem Abitur am Mons-Tabor Gymnasium in Montabaur studierte er Computervisualistik an der Universität Koblenz-Landau. Das Studium schloss er erfolgreich mit dem Titel Dipl.-Informatiker (mit Auszeichnung) ab und erhielt für seine Arbeiten u.a. den Hochschulpreis der Universität Koblenz-Landau. Nach dem Studium arbeitete er 6 Monate am Intelligent Robotics Lab der Universität Osaka in Japan an der Entwicklung von androiden Robotern mit. Seit 2006 ist er wissenschaftlicher Mitarbeiter am Lehrstuhl für Virtuelle Realität und Multimedia der Technischen Universität Bergakademie Freiberg, wo er 2010 seine Promotion mit Auszeichnung abschloss.