

Szenenanalyse und Unterscheidung der Skelette mehrerer Menschen in digitalen Bildern mit Graphentheorie durch eine k-kürzeste-disjunkte-Wege-Suche

Egbert Gedat*, Pascal Fechner, Richard Fiebelkorn, Ralf Vandenhouten

Zusammenfassung

Das Erkennen von Personen auf Fotos und in Videos geschieht in aktuellen Klassifizierungsverfahren durch die Zuordnung eines Körperteils zu jedem Pixel. Anschließend werden die gefundenen Körperteile zu Skeletten zusammengefasst. Im Falle mehrerer abgebildeter Personen ergibt sich das Problem der Zuordnung der Körperteile zu den verschiedenen Skeletten. Es wurde in dieser Arbeit ein auf dem Suurballe-Algorithmus basierendes graphentheoretisches Verfahren entwickelt, das diese Aufgabe löst. Aufbauend auf im Wesentlichen abstandsabhängigen Kantengewichten wird eine k-kürzeste-disjunkte-Wege-Suche durchgeführt. Unter Einbezug von möglicherweise fehlenden Körperteilen durch Unsichtbar-Knoten und automatisches Aussortieren zu viel gefundener Körperteile werden so die k-optimalen Skelette gefunden. Die Methode wurde an idealisierten computergenerierten Bildern mit einer Trefferquote von 100 % gefundener Personen getestet. Ein Test mit realen Bilddaten lieferte eine Trefferquote von 71,7 %.

Abstract

Recognition of humans on photos and in videos is done per current classification procedures by assigning a body part to each pixel. The body parts thus allocated are subsequently ordered into skeletons. In the case the images indicate that multiple humans are present, the problem arises of assigning the body parts to different skeletons. A Suurballe algorithm-based method developed by us solves this task. By mainly relying on distance-related edge weights, a k shortest disjoint paths search is performed. Accounting for possibly missing body parts by invisible-nodes and automatically sorting out redundant body parts, the optimal k skeletons are found. The method was tested with computer-generated data, yielding a rate of 100 % persons detected. A test with real-world images yielded a recall ratio of 71.7 %.

1. Einleitung

Automatisiertes Erkennen mehrerer Personen in Videos ist ein mächtiges Werkzeug für die Analyse des Verhaltens von Menschen in Gruppen. Aufbauend auf Ansätzen für die automatisierte Analyse der Pose einzelner Personen (Andriluka et al. 2009, Buys et al. 2014, Tran et al. 2008 und die darin zitierten Arbeiten) und Anwendungen in der medizinischen Therapie (Fraunhofer Fokus 2016) und in der Analyse von Sport (Bigontina et al. 2014) und Filmen (Laptev et al. 2008) wurden Erweiterungen für mehrere Personen entwickelt (Andriluka et al. 2012, Belagiannis et al. 2014, Luo et al. 2010, Kinect 2 Kamera für Windows (Microsoft

Corp., Redmond, WA, USA) mit OpenNI (<http://structure.io/openni>)).

In der hier vorgestellten Arbeit wurden für die Haltungserkennung die Skelette der Personen aus Körperteilen rekonstruiert. Bigontina et al. (2015) und Laptev et al. (2008) benutzten keine Skelette und Andriluka et al. (2009), Buys et al. (2014) und Tran et al. (2008) benutzten schematische Skelette ohne Anspruch auf anatomischer Korrektheit. Bei diesen wurde ein entweder vordefiniertes (Andriluka et al. 2009) oder aus einer Standardpose segmentiertes (Tran et al. 2008) Modell benutzt. Für die hier vorgestellte Erkennung der Skelette mehrerer Personen in Videos wurde ein graphentheoretischer Algorithmus entwickelt,

der auf dem von J. W. Suurballe für Netzwerke eingeführten k-kürzester-disjunkter-Wege-Algorithmus (Suurballe 1974) aufbaut. Andriluka et al. (2012) und Belagiannis et al. (2014) benutzten Zeichen-Boxen für jede Person und Luo et al. (2010) verwendeten personenabhängiges Markieren der Voxel, bevor die Skelette rekonstruiert wurden, so dass die Rekonstruktion auf jeweils ein Skelett reduziert wurde. Die Implementierung des hier vorgestellten Algorithmus ermöglicht die optimale Zuordnung einer Menge redundanter Körperteile zu einer diskreten Anzahl von Skeletten ohne vorherige Separation der Personen. Fehlende Körperteile wurden durch sog. Unsichtbar-Knoten modelliert.

* korrespondierender Autor

Die Güte der Skelettrekonstruktion hängt von der Qualität der Körperteilklassifikation ab, die ihr als Eingabedient. Um unabhängig hiervon den Algorithmus testen zu können, wurde er auf idealisierte Daten angewendet: Szenen aus der MOCAP-Datenbank (CMU Graphics Lab Motion Capture Database 2016) wurden in Blender (The Blender Foundation, Amsterdam, Niederlande) mit einer speziell hierfür entworfenen Textur gerendert. Weiter wurde der Algorithmus mit realen Bildern von Personen getestet, die mit einer Asus-Xtion-Pro-Kamera aufgenommen und mit der von den Autoren geschriebenen Software SkeletonApp, basierend auf Shottons Methode des maschinellen Lernens mit Entscheidungswäldern (Shotton et al. 2013), klassifiziert wurden. Ebenso spielt die anatomisch korrekte Lokalisation der Gelenke eine wichtige Rolle. Sie ist nicht Teil dieses Artikels und kann in Gedat et al. (2016) nachgelesen werden.

2. Die Körperteile und ihr Graph

Ein Graph im Sinne der Graphentheorie ist eine Verkettung von verschiedenen Elementen – den Knoten – durch zwischen ihnen bestehende Abhängigkeiten – die Kanten. Im vorliegenden Fall sind die Knoten die aus den Bildern gewonnenen Körperteile, von denen durch die Bildanalyse der Typ, also Arm oder Bein etc., und die Lage im Raum bekannt sind. Durch die Anatomie des Menschen werden dann Zielgraphen definiert; beispielsweise weiß man, dass die Reihenfolge Hals-Oberarm-Unterarm-Hand korrekt ist, und definiert diese als einen Teilgraphen des Skeletts mit den Knoten Hals, Oberarm, Unterarm und Hand. In dieser Reihenfolge versucht man dann aus den im Körperteil-Klassifizierungs-Algorithmus gefundenen Körperteilen die auszuwählen, die am besten zusammenpassen. Dafür werden die Kanten zwischen allen benachbarten Körperteilen (z. B. alle Händen mit allen Unterarmen) durch eine Gauss'sche Verteilung der wahrscheinlichsten Abstände der Körperteile berechnet. Wird der Graph einmal durchlaufen, liefert er das beste Ergebnis. Sollen nun mehrere k-beste Ergebnisse gefunden werden, reicht es nicht aus, die Suche einfach k-mal

unter Ausschluss der schon ausgewählten Körperteile durchzuführen, sondern man muss eine k-kürzeste-disjunkte-Wege-Suche durchführen. Diese stellt sicher, dass jedes Körperteil höchstens einmal benutzt wird und dass global die geringsten Kosten entstehen. Dafür müssen manchmal in der ersten Suche gefundene Körperteile nachträglich noch einem anderen Weg zugeordnet werden. Das leistet die k-mal ausgeführte kürzester-Weg-Suche nicht. Es wurde aber von J. W. Suurballe bereits im Jahr 1974 ein k-kürzeste-disjunkte-Wege-Algorithmus für Netzwerke vorgestellt, der das gewünschte Ergebnis liefert (Suurballe 1974).

Input für den hier vorgestellten Algorithmus sind die 3D-Positionen der Körperteile der abgebildeten Personen. Der Algorithmus erhält die Körperteile in Form von 3D-Punktwolken. Diese werden für reale Bilder von einem Klassifizierungsalgorithmus ermittelt, der jedem Bildpunkt eine Klasse entsprechend dem Körperteil oder als Hintergrund zuweist. Im Fall von 2D-Bildern muss hier stereoskopisch gearbeitet werden, um die 3D-Information zu erhalten. Dies ist im Fall der MOCAP-Bilder geschehen. Bei den realen Bildern wurde die Klassifikation auf der Basis von Tiefenbildern vorgenommen, die mit einer Asus-Xtion-Pro-Kamera zusätzlich zu den RGB Bildern aufgenommen wurden. Die Körperteilklassifikation ist eine hochkomplexe Aufgabe, an deren Lösung in 2D wie in 3D in dieser Forschungsgruppe gearbeitet wird, die aber nicht Gegenstand dieses Artikels ist. Die resultierenden Klassifikationen sind noch fehlerbehaftet, so dass für den Test des hier vorgestellten Algorithmus zur Skelettrekonstruktion mehrerer Personen Modelldaten generiert wurden. Dazu wurden von der frei zugänglichen CMU-MOCAP-Datenbank (CMU Graphics Lab Motion Capture Database 2016) Dateien verwendet, die die Koordinaten von Personen in verschiedenen Bewegungen enthielten. Mit diesen Koordinaten lässt sich ein mit der Software MakeHuman (MakeHuman team, www.makehuman.org) generierter Körper in die Software Blender einladen, mit einer geeigneten Textur (siehe Abb. 2) versehen und die Bewegung aus ver-

schiedenen Kameraperspektiven rendern. Die Körperteilklassifikation ist hier durch die Farbcodes der Figur eingearbeitet und somit perfekt, abgesehen von in 2D verdeckten Körperbereichen. Da die MOCAP-Datenbank nur Bewegungen einzelner Personen enthält, wurden diese nachträglich zusammengeschnitten, so dass Filme mit drei Personen entstanden, die sich nicht gegenseitig überdecken.

Die so gewonnenen Punktwolken der Körperteile werden weiter verrechnet, um die erwünschten 3D-Koordinaten zu gewinnen. Für eine anatomische Korrektur siehe Gedat et al. (2016). Die Körperteile wurden ausgehend vom Hals in 6 jeweils zusammenhängende Teilgraphen eingeteilt:

(1) linker Kopf

Hals, linker unterer/oberer Kopf

(2) rechter Kopf

Hals, rechter unterer/oberer Kopf

(3) linker Arm

Hals, linker Ober- und Unterarm, Hand

(4) rechter Arm

Hals, rechter Ober- und Unterarm, Hand

(5) linker Rumpf und Bein

Hals, linke Brust, Hüfte, Ober- und Unterschenkel, Fuß

(6) rechter Rumpf und Bein

Hals, rechte Brust, Hüfte, Ober- und Unterschenkel, Fuß

Dabei wird unterschieden in ‚zentrierte‘ Körperteile und solche, die durch ein mediales und ein distales Gelenk beschrieben werden. Letztere sind Ober- und Unterarm und Ober- und Unterschenkel. Alle anderen werden durch den Schwerpunkt beschrieben.

3. Implementierung der Algorithmen für die Skelette

Der Suurballe-Algorithmus ist Teil eines komplexeren Prozesses, der sich in mehrere Schritte gliedert: (i) Aufnahme/Generierung der Bilder, (ii) Klassifikation der Körperteile in den Bildern, (iii) Rekonstruktion der Skelette. Der Suurballe-Algorithmus findet im letzten Teil ‚Rekonstruktion der Skelette‘ statt, der sich wiederum in die folgenden Abschnitte gliedert: (i) Bestimmung der Gelenkpositionen, (ii) Anatomische Korrektur, (iii) Konstruktion der Adjazenzmatrix mit distanzabhängiger Kostenfunktion, (iv) Finden der besten Skelette mit dem Suurballe-Algorithmus, (v) Ausgabe der Daten zur Weiterverarbeitung, z. B. zur Gestenerkennung.

Die Adjazenzmatrix wird wie folgt erstellt. Die 3D-Koordinaten der Körperteile sind die Knoten des Graphen. Die Kanten berechnen sich als Kosten c_{ij}

$$c_{ij} = \begin{cases} 1 - p_{ij} & t_c < p_{ij} \leq 1 \\ \text{inf} & \text{sonst} \end{cases} \quad (1)$$

mit t_c als unterem Wahrscheinlichkeits-Schwellwert und den Wahrscheinlichkeiten p_{ij} zwischen den Knoten i und j

$$p_{ij} = \begin{cases} e^{\left\{ \frac{-(|r_i - r_j| - \mu_{ij})^2}{\sigma_{ij}^2} \right\}} & i, j \text{ Nachbarn} \\ 0 & \text{sonst} \end{cases} \quad (2)$$

mit den Körperteilpositionen r_i und r_j , dem mittleren Abstand der Körperteile μ_{ij} und der Standardabweichung des mittleren Abstandes der Körperteile σ_{ij} . μ_{ij} und σ_{ij} wurden aus Testdaten bestimmt.

Im Allgemeinen liefert der Klassifizierungsalgorithmus mehr Körperteile, als Personen im Bild sind, manchmal aber auch weniger. Die zu viel gefundenen Körperteile werden von dem Skelett-Rekonstruktions-Algorithmus aussortiert, indem sie nicht für die k kürzesten Wege berücksichtigt wurden. Für fehlende Körperteile muss in dem Graphen jeweils ein sog. Unsichtbar-Knoten eingeführt werden, damit der Algorithmus sein Ziel – das letzte Körperteil im Graphen – erreichen kann. Die Unsichtbar-Knoten helfen auch dabei, eventuell falsch gefundene Körperteile mit sehr hohen Kosten auszusortieren. Eine graphische Darstellung des Graphen für N Körperteile und k Personen ist in Abb. 1 gezeigt. Die Adjazenzmatrix ist ein Abbild des Graphen und wird für die k -kürzeste-disjunkte-Wege-Suche benutzt, die die k -besten Teilskelette findet. Der Algorithmus wird für die sechs Teilgraphen unabhängig durchgeführt. An-

schließend werden sie anhand des in allen Teilgraphen vorhandenen Halses zu ganzen Skeletten zusammengesetzt. Der Suurballe-Algorithmus startet mit einer einfachen kürzeste-Wege-Suche, dreht dann alle benutzten Kanten in die andere Richtung und spaltet alle benutzten Knoten in jeweils zwei Knoten auf, von denen einer alle eingehenden Kanten hat und der andere alle ausgehenden. Dann wird die kürzeste-Wege-Suche wiederholt. Für k kürzeste Wege wird die Prozedur $k - 1$ mal wiederholt. Die Implementierung des Suurballe-Algorithmus wurde gemäß Disjoint Path Finding (2016) realisiert. Abweichend wurde die Dijkstra-Methode anstatt der Bellman-Ford-Methode eingesetzt. Dies brachte eine Ersparnis an Rechenzeit und war möglich, weil gerichtete Kanten eingesetzt wurden. Die Algorithmen wurden in Matlab (The Mathworks, Natick, MA, USA) auf einem Standard-PC implementiert.

4. Ergebnisse und Diskussion

Der Algorithmus wurde zunächst zum Testen auf idealisierte computergenerierte Bilder angewendet. Diese zeichnen sich durch eine nahezu perfekte Körperteilklassifikation aus, lediglich perspektivisch verdeckte Körperteile können nicht dargestellt werden. Ein Beispiel ist in Abb. 2 gezeigt. MOCAP-Daten enthalten 4D-Koordinaten von Bewegungen. Es wurden alle 8 Bewegungen von Subjekt #56 ausgewählt. Mit MakeHuman wurde die Oberfläche der entsprechenden Personen erzeugt. In Blender wurde eine farbige Textur erzeugt, die die Körperteilklassifikation beinhaltet, und auf die Oberfläche gelegt. Dann wurden die Personen aus zwei Richtungen gerendert und stereoskopisch in 3D rekonstruiert. Da MOCAP-Daten grundsätzlich nur eine Person zeigen, wurden je drei Personen in jedem Bild zusammengesetzt.




Abb. 1) Der Graph für die Rekonstruktion der Skelette. Beispielhaft sind die Kanten für einen Graphen mit 3 Körperteilen und 3 Personen eingezeichnet. Es ist jede beliebige, endliche Anzahl N an Körperteilen und k an Personen möglich. Die Knoten stellen die in der Klassifikation gefundenen Körperteil-Cluster dar. Zusätzlich wurden unsichtbar-Knoten eingeführt, die fehlende Körperteile, wie hier beispielhaft bei Körperteil 2, oder mit hohen Kosten c_{ij} verbundene Körperteile ersetzen. Als Einsprungstelle wurde Start-Knoten 0.1 und als Ende der Ziel-Knoten 0.2 eingeführt. So durchläuft der Algorithmus den Graphen k mal von oben nach unten und berechnet die besten k Skelette.




Abb. 2) Skelette der mit MOCAP Daten gerenderten Personen.

Anschließend wurden reale Bilder von Menschen verwendet. Es wurden Tiefenbilder und RGB-Bilder mit einer Asus Xtion Pro Kamera aufgezeichnet. Die 3D-Punktwolken wurden mit unserer Software SkeletonApp nach Körperteilen klassifiziert. Ein Beispiel für reale Menschen ist in Abb. 3 gezeigt.

Die Anzahl der gefundenen Körperteil-Cluster und ihre Verwendung für die Skelette sind in Tab. 1 zusammengefasst.

Es wird deutlich, dass die Skelettrekonstruktion für ideale computergenerierte Daten über 90 % der Körper-

teile zuordnen kann und über 96 % der Cluster benutzt werden. Für reale Menschen findet aber die Körperteilklassifikation nicht alle Körperteile, so dass nur etwa 56 % der Körperteile in den Skeletten enthalten sind. Im Falle der MOCAP-Bilder sind die fehlenden Körperteile die in den Bildern nicht zu sehenden verdeckten Körperteile. Außerdem wird ersichtlich, dass die Körperteilklassifikation für reale Bilder zu viele – falsche – Cluster findet. Diese werden durch den Suurballe-Algorithmus korrekt aussortiert.

Die Qualität des Algorithmus lässt sich zudem gut an der Anzahl richtig

gefundenen in sich abgeschlossener Personen beurteilen. Abgeschlossen bedeutet hier, dass es keine Sprünge in Körperteile anderer Personen gibt. Diese Daten sind in Tab. 2 zusammengefasst.

Insgesamt zeigen die Ergebnisse, dass die Methode bei perfekt klassifizierten Bildern sehr gut funktioniert. Der Suurballe-Algorithmus ordnet die Körperteile korrekt den Skeletten zu. Bei realen Bildern ist die Zuordnung zu den Skeletten auch nahezu ohne Fehler, es werden aber nicht alle Skelette gefunden und bei den gefundenen Skeletten fehlen einige Körperteile. Es ergibt sich aber eine mit anderen Arbeiten vergleichbare Trefferquote. Andriluka et al. (2009, 2012) berichten für verschiedene Studien die Präzision und den Rückruf der Personendetektion im Bereich von 0,75 bis 0,95 am Break Even Point. Diese Werte liegen in der vorliegenden Arbeit bei jeweils 1,00 für MOCAP Bilder und 0,99 bzw. 0,72 für die Bilder mit realen Menschen. Die Zahlen belegen einen Skelett-Rekonstruktionsprozess auf dem neuesten Stand der Technik. Die Fehler bei der Anwendung auf reale Bilddaten sind vor allem auf die Vorverarbeitung durch den Körperteil-Klassifizierungs-Algorithmus zurückzuführen, der nicht alle Körperteile anbietet. Unsere derzeitigen Arbeiten konzentrieren sich deshalb auf eine Optimierung der Körperteilklassifikation.

5. Ausblick

Für die Optimierung der Methode und zur Verwertung in realen Szenarien gibt es drei wichtige Ansatzpunkte für weitere Arbeiten. Innerhalb der vorgestellten Skelettrekonstruktion wurden bisher nach einem fehlenden Körperteil alle folgenden Körperteile nicht weiter berücksichtigt. Die darin enthaltene Problematik kann eventuell durch eine modifizierte Form des Dijkstra-Algorithmus gelöst werden.

Das größte Augenmerk gilt aber dem Input in den Algorithmus. Wie die Ergebnisse gezeigt haben, ist die Körperteilklassifikation bei realen Filmen noch unvollständig. Dadurch geht Information verloren, die durch angepasste Klassifikationsalgorithmen bewahrt werden soll. Weiterhin erfordert



Abb. 3) Skelette realer Personen.

der aktuell benutzte Körperteilklassifikations-Algorithmus 3D-Daten einer Tiefenbildkamera. Dies ist für reale Szenarien nicht zufriedenstellend, so dass eine Ausweitung auf RGB-Daten ohne Tiefenbild angestrebt wird.

6. Danksagung

Diese Arbeit wurde gefördert vom Bundesministerium für Bildung und Forschung im Förderprogramm FH-profUnt, Förderkennzeichen 03FH-009PX3.

Die MOCAP-Daten, die in diesem Projekt benutzt wurden, stammen von mocap.cs.cmu.edu. Die Datenbank wurde errichtet mit Förderung der NSF EIA-0196217.

LITERATUR

Andriluka M, Roth S, Schiele B (2009) Pictorial Structures Revisited: People Detection and Articulated Pose Estimation. IEEE Conference on Computer Vision and Pattern Recognition: 1014-1021. doi: 10.1109/CVPR.2009.5206754

Andriluka M, Roth S, Schiele B (2012) Discriminative Appearance Models for Pictorial Structures, International Journal of Computer Vision 99(3): 259-280. doi: 10.1007/s11263-011-0498-z

Belagiannis V, Amin S, Andriluka M, Schiele B, Navab N, Ilic S (2014) 3D Pictorial Structures for Multiple Human Pose Estimation. IEEE Conference on Computer Vision and Pattern Recognition: 1669-1676. doi: 10.1109/CVPR.2014.216

Bigontina A, Herrmann M, Hoernig M, Radig B (2014) Human Body Part Classification in Monocular Soccer Images. In: Paulus D, Fuchs C, Droege D (eds) Proceedings of the 9th Open German-Russian Workshop on Pattern Recognition and Image Understanding. 2014, Koblenz. Active Vision Group, Koblenz, pp 128-131

Buys K, Cagniard C, Baksheev A, De Laet T, De Schutter J, Pantofaru C (2014) An adaptable system for RGB-D based human body detection and pose estimation. Journal of Visual Communication and Image Representation 25 (1): 39-52. doi: 10.1016/j.jvcir.2013.03.011

CMU Graphics Lab Motion Capture Database (2016). <http://mocap.cs.cmu.edu/>. Accessed 25 Aug 2016

Disjoint Path Finding (2016). http://www.macfreak.nl/memory/Disjoint_Path_Finding. Accessed 25 Aug 2016

Fraunhofer Fokus (2016) MyRehab. <https://www.fokus.fraunhofer.de/go/myrehab>. Accessed 25 Aug 2016

Gedat E, Fiebelkorn R, Vandenhousten R (2016) Multiple Human Skeleton Recognition in RGB and Depth Images with Graph Theory, Anatomic Refinement of Point Clouds and Machine Learning. In: 2016 IEEE International Conference on Systems, Man, and Cybernetics

Laptev I, Marszałek M, Schmid C, Rozenfeld B (2008) Learning realistic human actions from movies, IEEE Conference on Computer Vision and Pattern Recognition: 1-8. doi: 10.1109/CVPR.2008.4587756

Luo X, Berendsen B, Tan RT, Veltkamp RC (2010) Human Pose Estimation for Multiple Persons Based on Volume Reconstruction, IEEE International Conference on Pattern Recognition: 3591-3594. doi: 10.1109/ICPR.2010.876

Tab. 1: Verwendung der Körperteil-Cluster für die Skelette in MOCAP-Daten und für reale Menschen. ‚Körperteile‘ sind alle anatomisch möglichen Körperteile, ‚gefundene Körperteile‘ die von dem hier vorgestellten Algorithmus für die Skelette verwendeten Körperteile, ‚Cluster‘ die von dem Körperteilklassifizierungsalgorithmus gefundenen Cluster und ‚benutze Cluster‘ die von dem hier vorgestellten Algorithmus für die Skelette verwendeten Cluster.

		Körperteile	gefundene Körperteile	Cluster	benutzte Cluster
MOCAP	Anzahl	4.284	3.899	4.032	3.899
	Prozent	100	91.0	100	96.7
Reale Menschen	Anzahl	2.079	1.166	2.679	1.166
	Prozent	100	56.1	100	43.2

Tab. 2: Präzision der Skelettdetektion

	detektierte Personen	richtige Personen	Sprünge zu anderen Personen
MOCAP (n = 204)	100 %	100 %	0 %
Reale Menschen (n = 99)	72,7 %	71,7 %	1,0 %

Shotton J, Girshick R, Fitzgibbon A, Sharp T, Cook M, Finocchio M, Moore R, Kohli P, Criminisi A, Kipman A, Blake A (2013) Efficient Human Pose Estimation from Single Depth Images. IEEE Transactions on Pattern Analysis and Machine Intelligence 35 (12): 2821-2840. doi 10.1109/TPAMI.2012.241

Suurballe JW (1974) Disjoint Paths in a Network. Networks 4 (2): 125-145. doi: 10.1002/net.3230040204

Tran C, Trivedi MM (2008) Human body modelling and tracking using volumetric representation: Selected recent studies and possibilities for extensions. Second ACM/IEEE International Conference on Distributed Smart Cameras: 1-9. doi: 10.1109/ICDSC.2008.4635733

AUTOREN

Dr. rer. nat. Egbert Gedat
Pascal Fechner, Dipl.-Inform.
Richard Fiebelkorn, Dipl.-Ing. (FH)
Prof. Dr. rer. nat. Ralf Vandenhousten
 Forschungsgruppe Telematik
 Fachbereich Ingenieur- und Naturwissenschaften
 Technische Hochschule Wildau

E-Mail für Korrespondenz:
 gedat@th-wildau.de

