

Diagnose emotionaler Zustände beim Gang mittels neuronaler Netze

1. Einleitung

Nicht nur etymologisch scheint es Zusammenhänge zwischen Bewegung und Emotion (*lat. e: „aus“; lat. movere: „bewegen“*) zu geben. Auch die Frage „Wie geht's?“ deutet auf eine Verbindung hin.

Quantitative Hinweise für einen Zusammenhang zwischen dem Grad der Depression und dem Gangmuster bei depressiven Patienten lieferten Sloman et al. (1982). Dabei korreliert ein hoher Grad an Depression mit einer schlep-penden Fortbewegung, während sich nichtdepressive Probanden eher an-treibend fortbewegen. Tendenziell bestätigt werden konnte dies an einem ge-sunden Probandenkollektiv mit unterschiedlicher Stimmungsvalenz (Sloman et al., 1987). Beckers und Deckers (1997) fassen dies folgendermaßen zu-sammen:

„In der Art, wie wir gehen, spiegelt sich fortwährend unsere körperliche als auch innere Verfassung wider“ (Beckers & Deckers, 1997, S. 1).

Inwiefern sich Emotionen am Gangbild Gesunder visuell erkennen lassen, war Gegenstand der Untersuchung von Montepare et al. (1987). Hierzu wur-den Probanden Videos mit emotionsgefärbten Gangmustern dargeboten. Diese konnten die Videos den Emotionen Freude, Trauer, Stolz und Wut überzufällig gut zuordnen.

Aktuelle Untersuchungen zur Emotionserkennung sind - unterstützt durch die Mittel und Methoden der Informatik - hauptsächlich im Bereich der Gesichts-erkennung (Schweiger et al., 2004; Ioannou et al., 2005) und Spracherken-nung (Nicholson et al., 2000; Nwe et al., 2003; siehe auch *Themenheft „Affective Speech Processing“ in Lecture notes in computer science, Bd. 3784, 2005*) oder als Kombination aus beiden (Fragopanagos & Taylor, 2005; Park et al., 2005) zu finden. Der primäre Anwendungsbereich dieser Emotionserkennungssysteme ist (neben dem Einsatz in der Forensik) zur Verbesserung von Spracherkennungssoftware, für intelligente Tutoring-Systeme und zur Verbesserung der Mann-Maschine-Kommunikation (z.B. in der Spielein-dustrie) zu sehen.

Walk und Homan (1984) weisen in diesem Zusammenhang auf die zusätzli-che motorische Ausdrucksform von Emotionen hin:

„Although emotion may be expressed in the face, it can also be expressed in the voice and in body movement. People jump with joy or cringe with fear” (Walk & Homan, 1984, S. 437).

Ziel der folgenden Untersuchung ist eine quantitative Erkennung und Zuordnung von Emotionszuständen und Stimmungen anhand des menschlichen Gangs mittels künstlicher neuronaler Netze. Hierzu wurden die Gangmuster von 22 Probanden auf ihre Individualität und auf die Erkennung und Zuordnung von dargestellten Emotionen untersucht.

2. Methoden

Mit Hilfe einer Kistler-Kraftmessplatte (1000Hz) wurden die Bodenreaktionskräfte beim Gehen von 22 gesunden Probanden während eines Bodenkontakts erhoben. In selbst bestimmter Geschwindigkeit sollten die Probanden während des Gehens vier emotionale Zustände darstellen: Angst, Wut, Trauer und neutral. Jeder Zustand wurde drei Mal hintereinander demonstriert, die Reihenfolge der darzustellenden Emotionen wurde randomisiert festgelegt. Der Experimentaufbau ist in Abb. 1 dargestellt. Es wurden kinetische und kinematische Daten (Schöllhorn & Lubienetzki, 2005) erhoben, hier jedoch nur kinetische Daten ausgewertet.




Abb. 1: Experimentaufbau. Gangrichtung von rechts nach links.

Die Datenaufnahme der kinetischen Daten erfolgte mit Dasy-Lab, die Weiterverarbeitung mit Matlab. Die Daten wurden zeitnormiert und probandenweise amplitudennormiert. Danach erfolgte von jedem Gangmuster eine Subtraktion des Mittels aller Gangmuster, um die individuelle Charakteristik des Gangs stärker zu betonen. Berücksichtigt wurden neben der Vertikalkraft (z-

Dimension) auch die horizontale Scherkraft (x-Dimension) und die Progressionsscherkraft (y-Dimension).

Die Klassifizierung der Daten erfolgte mit zwei verschiedenen neuronalen Netzen, von denen das Feedforward-Netz (FFN) mit Backpropagation Lernalgorithmus als überwachtes Lernverfahren zur Erkennung individueller Gangmuster und die Selbstorganisierende Karte (SOM) als unüberwachtes Lernverfahren zur Klassifizierung der Emotionen genutzt wurde (Lippe, 2006).

Die Anzahl der Eingabeneuronen des FFN richtete sich nach der Anzahl der ausgewählten Stützstellen der Daten. Ein Optimum stellte sich erst bei einer Verwendung von 100 Werten für die Vertikalkraft und 100 Werten für beide horizontalen Kräfte ein. Pro Klasse wurde ein Ausgabeneuron angelegt und als Anzahl der verdeckten Neuronen $n/2$ Neuronen gewählt ($n = \text{Eingabeneuronen} + \text{Ausgabeneuronen}$). Ein Gangmuster konnte so einer Person zugeordnet werden, wenn das entsprechende Ausgabeneuron der dazugehörigen Person „feuerte“. Die Erkennungsrate des Netzes [in %] berechnete sich aus der richtig klassifizierten Anzahl an Mustern. Die Gewichtsmatrix wurde randomisiert initialisiert, als Transferfunktion wurde in allen Schichten der Tangens Hyperbolicus gewählt, als Lernregel diente der Scaled Conjugate Gradient Algorithmus (Møller, 1993). Alle Erkennungsraten wurden anhand unbekannter Testdaten (Verhältnis Trainingsdaten zu Testdaten: 2:1) errechnet und mittels einfacher Kreuzvalidierung gemittelt.

Als Selbstorganisierende Karte wurde eine hexagonale SOM mit Batchtraining und der Größe von 5x3 Neuronen gewählt. Die normalisierte Gaußfunktion diente als Nachbarschaftsfunktion, die Datenabtastung betrug jeweils 50 Werte für die Vertikalkraft und für beide Horizontalkräfte zusammen. Ermittelte Erkennungsraten stellen ein selbst implementiertes Gütekriterium für die Klassifikationsleistung der SOM dar, bei dem die Prozentzahl der richtig klassifizierten Emotionen in bestehende Klassencluster bei simulierter Präsentation der Trainingsdaten bestimmt wird.

3. Ergebnisse

Ein mit 400 Epochen trainiertes FFN war in der Lage, alle 22 Probanden zu 95,6% am Gangmuster zu unterscheiden. Lediglich eine Reduktion der Testdatenmenge zugunsten der Trainingsdatensatzgröße führt zu einer weiteren Performancesteigerung.

Eine individuenübergreifende Erkennung von Emotionszuständen war allerdings anhand der kinetischen Daten nicht möglich. Auf intraindividuelle Ebene konnten jedoch Erkennungsraten bis 100% (im Schnitt 83,7%) erreicht werden (5x3 SOM, Trainingslänge: 50 Epochen, Lernrate $\alpha=0,5$ im rough training bzw. 0.05 im finetuning). In Abb. 2 ist die Verteilung der Gangmuster einer Probandin nach Emotionen aufgeschlüsselt dargestellt.




Abb. 2: Verteilung der kinetischen Gangmuster einer Probandin auf die SOM, aufgeschlüsselt nach Emotionen. Dunkle Bereiche in der Unified Distance Matrix (links) geben Clustergrenzen an, helle Bereiche kennzeichnen Cluster.

4. Diskussion

Die ermittelten Erkennungsraten bzw. Klassifikationen liefern Hinweise für eine individuelle Spiegelung von Emotionen selbst in hoch automatisierten Bewegungen. Eine individuenübergreifende Erkennung von Emotionen war nicht möglich und deutet auf eine individuelle Darstellung von Emotionen hin. Auf intraindividuelle Ebene war die Unterscheidung der emotionalen Zustände meist gut erreichbar. Offensichtlich stellt der individuelle Gang eine Grobklassifikation dar, wohingegen die individuelle Darstellung der Emotionen eine Feinstruktur liefert. Ähnlich wie in Abb. 2 dargestellt war bei 21 von 22 Probanden zumindest der Gegenpol *Trauer* und *Wut* deutlich zu erkennen. Bei 9 von 22 Probanden war zusätzlich die Ausrichtung der Valenz „aktivierend“ und „deaktivierend“ (Hesse, 2003) dergestalt zu beobachten, dass *Wut* und *Freude* in benachbarten Regionen der SOM lagen, während *Trauer* diesen gegenüber lag.

Aufgrund der geringen Größe der Datensätze können keine verallgemeinernden Aussagen getroffen werden, neben der Relevanz der vorgestellten Untersuchungsmethode für eine individuelle Therapie im klinischen Bereich und ihren Gesamtverlauf bieten sich jedoch auch im Bereich des Sports vielfältige Anwendungsmöglichkeiten an. Ist der emotionale Zustand eines Athleten zu Beginn eines Trainings bekannt, können individuell (stimmungsangepasst) abgestimmte Inhalte und Umfänge angeboten werden, um Über- oder Fehlbelastungen zu vermeiden. In diesem Zusammenhang gelang es Jäger et al., (2003), den Ermüdungszustand von Probanden (ermüdet – nicht ermüdet) anhand kinetischer Daten zu 100% richtig zu unterscheiden.

Coombes et al. (2005) und Coombes et al. (2006) zeigten ferner, dass emotionsauslösende Stimuli Einfluss auf die Koordination und isometrische Kraftproduktion von Probanden hatten. Da auch die Ergebnisse dieser Untersu-

chung den Einfluss von Emotionen auf Bewegungen herausstellen, erscheint es als lohnenswert, der Frage nachzugehen, inwieweit innerhalb des Trainings emotionale Einflüsse eine stärkere Berücksichtigung finden sollten und sich für die Rekrutierung weiterer Leistungsreserven nutzen lassen.

Autoren

DANIEL JANSSEN, JESSICA LUBIENETZKI, WOLFGANG I. SCHÖLLHORN:
Westfälische Wilhelms-Universität Münster, Institut für Sportwissenschaft.

Literatur

Beckers, D. & Deckers, J. (1997). *Ganganalyse und Gangschulung: therapeutische Strategien für die Praxis*. Berlin; Heidelberg [u.a.]: Springer.

Coombes, S.A., Cauraugh, J.H., & Janelle, C.M. (2006). Emotion and movement: Activation of defensive circuitry alters the magnitude of a sustained muscle contraction. *Neuroscience Letters*, 396 (3), 192-196.

Coombes, S.A., Janelle, C.M., & Duley, A.R. (2005). Emotion and motor control: Movement attributes following affective picture processing. *Journal of Motor Behavior*, 37 (6), 425-436.

Fragopanagos, N. & Taylor, J.G. (2005). Emotion recognition in human-computer interaction. *Neural Netw.*, 18 (4), 389-405.

Hesse, H.P. (2003). *Musik und Emotion. Wissenschaftliche Grundlagen des Musik-Erlebens*. Wien u.a.: Springer.

Ioannou, S.V., Raouzaïou, A.T., Tzouvaras, V.A., Mailis, T.P., Karpouzis, K.C., & Kollias, S.D. (2005). Emotion recognition through facial expression analysis based on a neurofuzzy network. *Neural Networks*, 18 (4), 423-435.

Jäger, J.M., Alichmann, M., & Schöllhorn, W.I. (2003). Erkennung von Ermüdungszuständen anhand von Bodenreaktionskräften mittels neuronaler Netze. In G. P. Brüggemann & G. Morey-Klapsing (Eds.), *Biologische Systeme - Mechanische Eigenschaften und ihre Adaptation bei körperlicher Belastung* (S. 179-183). Hamburg: Czwalina.

Lippe, W.M. (2006). *Soft-Computing. Mit Neuronalen Netzen, Fuzzy-Logic und Evolutionären Algorithmen*. Berlin, Heidelberg: Springer.

Møller, M.F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural Networks*, 6, 525-533.

Nicholson, J., Takahashi, K., & Nakatsu, R. (2000). Emotion recognition in speech using neural networks. *Neural Computing & Applications*, 9 (4), 290-296.

Nwe, T.L., Foo, S.W., & De Silva, L.C. (2003). Speech emotion recognition using Hidden Markov models. *Speech Communication*, 41, 603-623.

Park, C.H., Byun, K.S., & Sim, K.B. (2005). The Implementation of the Emotion Recognition from Speech and Facial Expression System. *Lecture Notes in Computer Science*, 3611, 85-88.

Schöllhorn, W.I. & Lubienetzki, J. (2005). Process-oriented analysis of kinematic gait patterns within families. In G. Huber, E. Schneider, & M. Morlock (Eds.), *Jahrestagung der DGfB biomechanica V* (S. 110). Hamburg: TuTech Innovation GmbH.

Schweiger, R., Bayerl, P., & Neumann, H. (2004). Neural architecture for temporal emotion classification. *Affective Dialogue Systems, Proceedings*, 3068, 49-52.

Sloman, L., Berridge, M., Homatidis, S., Hunter, D., & Duck, T. (1982). Gait patterns of depressed patients and normal subjects. *Am.J.Psychiatry*, 139 (1), 94-97.

Sloman, L., Pierrynowski, M., Berridge, M., Tupling, S., & Flowers, J. (1987). Mood, depressive illness and gait patterns. *Can.J.Psychiatry*, 32 (3), 190-193.

Walk, R.D. & Homan, C.P. (1984). Emotion and Dance in Dynamic Light Displays. *Bulletin of the Psychonomic Society*, 22 (5), 437-440.