

Lernen situationsunabhängiger Personenerkennung

Marco K. Müller · Michael Tremer
Christian Bodenstein · Rolf P. Würtz

Einleitung

In den vergangenen 25 Jahren hat sich automatische Gesichtserkennung von einem akademischen Projekt zu einer reifen Technik entwickelt. Bei der Frage, ob es sich auf zwei Fotos um die gleiche Person handelt, sind kommerzielle Systeme inzwischen sogar Menschen überlegen [6]. Dies ist nicht mit der Erkennung von bekannten Personen zu verwechseln, die der Mensch in sehr vielen verschiedenen Situationen auch nach vielen Jahren wiedererkennen kann.

Es ist eine zentrale Aufgabe des Computersehens, bekannte Objekte in Bildern wiederzuerkennen. Dies ist schwierig, weil dasselbe Objekt in verschiedenen Situationen sehr verschiedene Bilder erzeugt. Menschliche Wahrnehmung kann sehr leicht und unbewusst von diesen Situationen abstrahieren, beispielsweise ist die Gesichtserkennung in einem weiten Bereich unabhängig von der Entfernung, der Kopfpose und den Beleuchtungsverhältnissen. Dies wird auch invariante Erkennung genannt.

Bei allen erfolgreichen Erkennungssystemen wurde diese Invarianzleistung von Hand eingebaut, d. h., im Wesentlichen müssen viele Situationen durchgespielt und die beste Ähnlichkeit gesucht werden. Dies gilt auch für das *Elastische Bündelgraphenmatching (EBGM)* [4, 9]. Hier wird eine *Galerie* gespeicherter Gesichter durch Graphen repräsentiert, deren Knoten auf bestimmten Punkten, genannt *Landmarken*, im Gesicht liegen, die für alle Gesichter möglichst die gleichen sind (s. Abb. 1). Die visuellen Merkmale an diesen Knoten sind in „Bündel“ organisiert, die ganze Galerie besteht aus einem Bündelgraphen. Soll nun die Identität einer Person in einem neu aufgenommenen *Pro-*

benbild wiedererkannt werden, müssen durch einen Optimierungsprozess (Matching) anhand lokaler Bildmerkmale die korrespondierenden Punkte wiedergefunden werden. Als wiedererkannt gilt die Person, bei der die durchschnittliche Ähnlichkeit ihrer lokalen Merkmale zu den entsprechenden im Probenbild größer ist als bei allen anderen Personen.

Falls das Gesicht der Person nur verschoben oder, z. B. durch Mimik, leicht verformt ist, ist dies ohne weiteres möglich. Bei stärkeren Kopfdrehungen oder Beleuchtungsänderungen verändern sich aber die lokalen Merkmale so stark, dass andere Personen in der gleichen Situation ähnlicher werden als die richtige Person in einer anderen. Um dies zu beheben, muss im Grunde für jede neue Situation auch ein neuer Bündelgraph erstellt werden.

Dies ist im Sinne des Organic Computing [5, 10, 11] ein unvertretbarer Aufwand. Von einem selbstorganisierenden Erkennungssystem muss man verlangen, dass es mit wenigen Bildern einer neuen Person auskommt und die Veränderungen durch verschiedene Situationen aufgrund seiner allgemeinen „Lebenserfahrung“ gelernt hat. Dies spaltet das Lernen in zwei sinnvolle Phasen auf, nämlich das Lernen der allgemeinen Regel, wie sich ein Gesicht in verschiedenen Situationen verhält, und das Lernen neuer Individuen anhand weniger oder nur einer

DOI 10.1007/s00287-012-0598-3
© Springer-Verlag 2012

Marco K. Müller · Michael Tremer
Christian Bodenstein · Rolf P. Würtz
Institut für Neuroinformatik, Ruhr-Universität Bochum,
44780 Bochum
E-Mail: marco.k.mueller@rub.de, michael.tremer@ini.rub.de,
christian.bodenstein@ini.rub.de, rolf.wuertz@ini.rub.de

Zusammenfassung

In den vergangenen Jahren hat die automatische Gesichtserkennung so große Fortschritte gemacht, dass kommerzielle Systeme teilweise bessere Erkennungsraten erreichen als Versuchspersonen. Dennoch bleibt die Erkennung in verschiedenen Situationen schwierig. Wir stellen ein System vor, das auf Ranglistenähnlichkeit basiert und, getreu den Prinzipien von Organic Computing, Veränderung der Situation rein aus Beispielen lernt. Wir demonstrieren den Erfolg am Beispiel von Posen- und Beleuchtungsänderungen anhand einer großen Datenbank chinesischer Gesichter. Die Auswertung kann durch ein schnelles puls-basiertes neuronales Netzwerk erfolgen.

Situation. Dieses Verhalten ist, wie z. B. in [7] gefordert, weder komplett von oben geplant noch völlig frei, sich beliebig zu entwickeln. Die Kontrolle entsteht durch Auswahl geeigneter Trainingsdaten in beiden Phasen. Dennoch ist der Aufwand gegenüber einem Design des kompletten Systems deutlich reduziert.

Die Veränderungen in verschiedenen Situationen sollten im Prinzip aus geometrischen und beleuchtungstechnischen Modellen herleitbar sein. Leider waren Versuche in dieser Richtung wenig erfolgreich, da sie genaue Kenntnis der dreidimensionalen Gesichtsform und ein genaues Modell der Lichtreflexion an menschlicher Haut erfordern würden. Beide sind nach derzeitigem Kenntnisstand nicht in ausreichender Genauigkeit herstellbar.

Man kann aber erwarten, dass Gesichter, die sich in einer Situation ähnlich sehen, dies auch in anderen tun. Wenn das der Fall ist, dann kann man die Ähnlichkeiten eines Bildes zu verschiedensten Personen in der gleichen Situation als Beschreibung dieser Person verwenden.

Ähnlichkeiten im EBG

Elastische Graphen bestehen aus N Knoten, die auf Gesichtern positioniert sind und die Bildinformationen mithilfe lokaler Bildmerkmale, sog. Gaborjets, tragen. Die Ähnlichkeit dieser Gaborjets wird mithilfe einer Vergleichsfunktion S_J ermittelt, die maximal ist, wenn die Jets gleich sind. Die Galeriegraphen G_g haben die Jets $G_{g,n}$, für das Probenbild sind die Jets $P(x)$ an allen Bildpunkten x bekannt. Die Positionierung der Knoten x_n im Probenbild (das Matching) erfolgt durch Optimierung der Ähnlichkeit

$$\frac{1}{N} \sum_{n=1}^N \max_g S_J(P(x_n), G_{g,n}).$$

Wenn die Knoten im Probenbild richtig positioniert sind, hat der Graph P , der das Probenbild repräsentiert, am Knoten n den Jet $P_n = P(x_n^{\text{opt}})$. Die Ähnlichkeit der Personen ergibt sich als Durchschnitt der lokalen Knotenähnlichkeiten, und die erkannte Person ist die mit der größten Ähnlichkeit zum Probenbild

$$g_{\text{rec}} = \arg \max_g \frac{1}{N} \sum_{n=1}^N S_J(P_n, G_{g,n}).$$

Erkennung mit Ranglisten

Diese Ähnlichkeiten sind nutzlos, wenn die Situationen verschieden sind. Genauer, die Berechnung

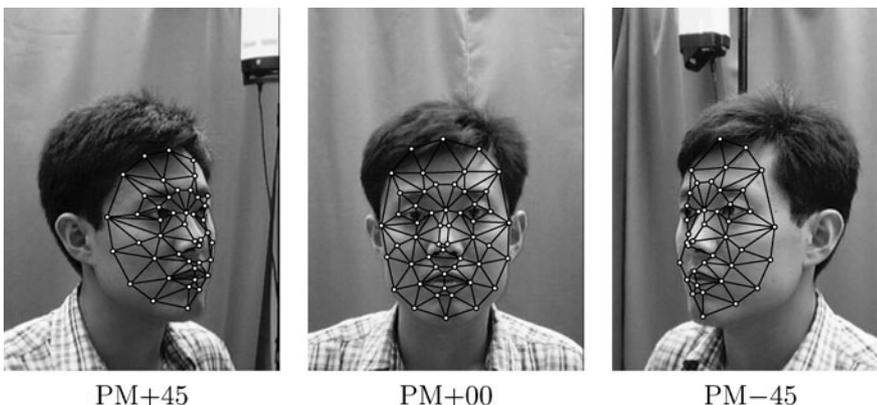


Abb. 1 Das grundlegende Datenformat für Gesichtserkennung durch Elastisches Bündelgraphenmatching sind Graphen mit Knoten auf festen Punkten im Gesicht. In der gleichen Situation haben diese Graphen die gleiche Topologie und sind vergleichbar, in unterschiedlichen Situationen dagegen nicht

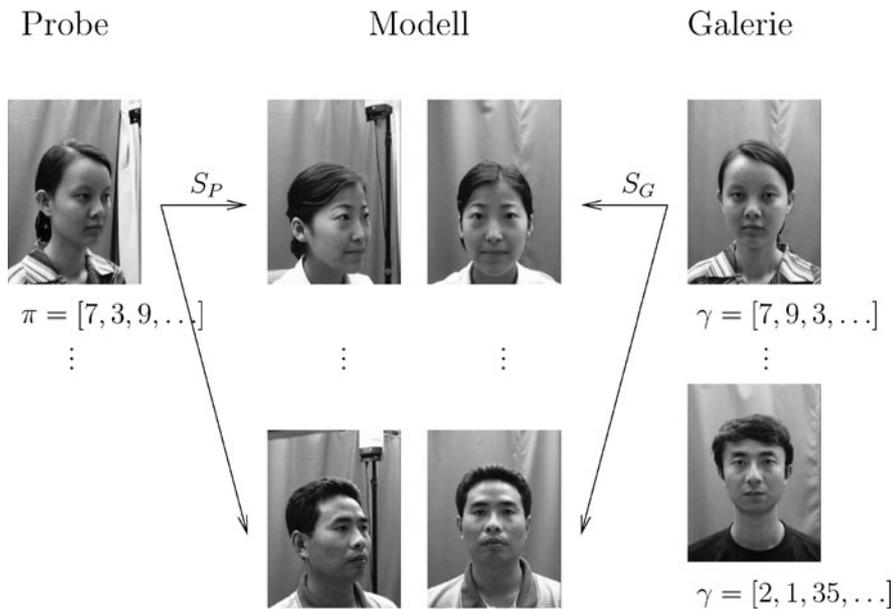


Abb. 2 Aufgabe der Gesichtserkennung ist es, ein Probenbild mit vielen gespeicherten Galeriebildern zu vergleichen, um die ähnlichste Person zu finden. Bei stark unterschiedlichen Situationen ist dies nicht direkt möglich. Situationsunabhängige Erkennung wird durch eine Modelldatenbank erreicht, die einige Personen in allen möglichen Situationen enthält. Einzelne Knoten der Probe- und Galeriegraphen werden als Ranglisten π und γ nach den Ähnlichkeiten zu den entsprechenden Knoten der Modelle in der gleichen Situation kodiert

von $S_j(P_n, G_{g,n})$ ist nur sinnvoll, wenn beide Graphen Bilder in der gleichen Situation darstellen. In Abb. 2 kann man also die Bilder in der ersten Spalte mit denen der zweiten vergleichen, ebenso die der dritten und vierten. Erforderlich ist aber ein Vergleich der Probenbilder mit den Galeriebildern.

Eine Modelldatenbank, die eine gewisse Zahl N_M von Personen in mehreren Situationen enthält, kann diesen Vergleich liefern. Die entsprechenden Graphen haben die Jets $M_{m,n}^v$, wobei v die Situation beschreibt. Unter der oben gemachten Annahme, dass Personen, die sich in einer Situation ähneln, dies auch in anderen Situationen tun, kann man eine Person durch ihre Ähnlichkeit zu allen Modellpersonen in der gleichen Situation repräsentieren.

Die Repräsentation eines beliebigen Gesichtsgraphen in Situation v mit Jets T_n^v hat die Form einer Rangliste r_n^v d. h. einer Funktion von $\{1, \dots, N_M\}$ in $\{1, \dots, N_M\}$, die die Reihenfolge der Ähnlichkeiten angibt:

$$r_n^v(m) < r_n^v(m') \Rightarrow S_j(T_n^v, M_{m,n}^v) \geq S_j(T_n^v, M_{m',n}^v). \quad (1)$$

Das Modell mit der höchsten Ähnlichkeit erhält also den Rang 1, das mit der zweithöchsten den Rang 2, usw.

Die Ranglisten für die Galeriebilder entstehen durch Vergleiche mit Modellbildern der Situation $v = 0$ und heißen γ , die der Probenbilder P^v in Situation v mit den Modellbildern derselben Situation werden mit π^v bezeichnet:

$$\gamma_{g,n}(m) = r_n^0(G_g, m), \quad m = 1 \dots N_M, \quad (2)$$

$$\pi_n^v(m) = r_n^v(P^v, m), \quad m = 1 \dots N_M. \quad (3)$$

Wenn alle Knoten der Galerie- und Probenbilder als Ranglisten konstanter Länge N_M kodiert sind, braucht man nur noch eine Vergleichsfunktion für solche Ranglisten. Diese sollte die folgenden Eigenschaften haben:

- Identische Ranglisten sollten die maximale Ähnlichkeit haben.
- Die Ähnlichkeit sollte hoch sein, wenn identische Modellindizes oft denselben Rang haben.
- Kleine Ranglisteneinträge (die somit zu einer höheren Ähnlichkeit gehören) sollten stärker gewichtet werden.

Diese Bedingungen werden erfüllt, wenn eine streng monoton fallende Funktion auf die Summe der

Ranglisten angewendet wird, z. B. eine Exponentialfunktion ($\lambda < 1$)

$$S_{\text{rank}}(\pi, \gamma_g) = \frac{1}{N_M} \sum_{m=1}^{N_M} \lambda^{\pi(m) + \gamma_g(m)}.$$

Diese Ranglistenähnlichkeit kann für alle Landmarken in den Gesichtern durchgeführt werden. Diese sind so nummeriert, dass korrespondierende Landmarken in allen Situationen die gleiche Nummer n haben. Da nicht alle Landmarken in allen Situationen vorhanden sind, wird die entsprechende Menge in Situation v als \mathcal{L}^v bezeichnet

$$S_{\text{rec}}(g) = \frac{1}{|\mathcal{L}^v \cap \mathcal{L}^0|} \sum_{n \in \mathcal{L}^v \cap \mathcal{L}^0} S_{\text{rank}}(\pi_n^v, \gamma_{gn}). \quad (4)$$

Wie beim Bündelgraphenmatching ist die erkannte Person die mit dem Index g , der diese Ähnlichkeit maximiert.

Ein puls-basiertes neuronales Netzwerk

Die enorme Geschwindigkeit, mit der visuelle Reize vom menschlichen Gehirn verarbeitet werden, stellt die Frage, in welcher Form die Information dabei übertragen wird. Die gemessenen Reaktionszeiten bei der Erkennung bekannter Objekte oder Gesichter lassen schließen, dass Neurone nur ein einziges Mal feuern können, sodass die Möglichkeit der Informationsweitergabe über Feuerraten hierbei nicht möglich ist. Daher haben Thorpe et al. eine neuronale Verschaltung vorgestellt, die davon ausgeht, dass die Information in der Feuerreihenfolge verschiedener Neurone vorliegt [8]. Die Verschaltung ist in der Lage, selektiv auf verschiedene Reihenfolgen zu reagieren (Abb. 3).

Die linke Hälfte von Abb. 3 stellt dieses Subnetzwerk dar. Die präferierte Feuerreihenfolge ist in den Gewichten w_j kodiert, dabei entspricht ein zuerst feuerndes Neuron dem größten Gewicht. Feuert nun eines der Neurone a_j , so leitet es seine Aktivität über exzitatorische Synapsen an das Neuron E weiter, erhöht jedoch auch die Aktivität des Neurons I, das inhibitorisch mit dem Neuron E verbunden ist. Diese sukzessiv ansteigende Hemmung des Neurons E sorgt dafür, dass die Aktivität des zweiten Neurons a_j weniger stark gewichtet wird als die des ersten und so weiter. Auf diese Weise ist die Aktivierung des Neurons E dann maximal, wenn die Feuerreihenfolge der Neurone a_j genau der Stärke der Gewichte w_j entspricht.

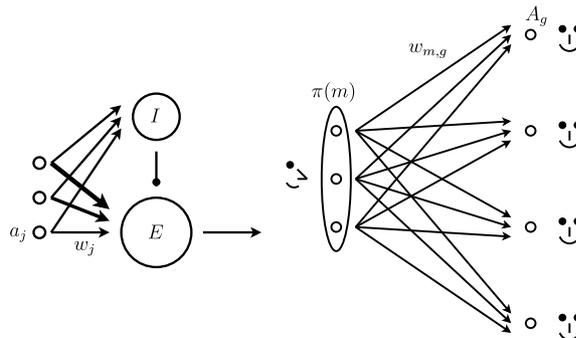


Abb. 3 Links: Prinzip des neuronalen Schaltkreises, der selektiv auf eine eingehende Feuerreihenfolge reagiert (nach [8]). Rechts: Dieses Modul wird für alle Knoten (hier nicht gezeigt) aller Galeriebilder wiederholt. Ein Probenbild ist als Rangliste π kodiert. Das Netzwerk erzeugt für vier verschiedene Galerieidentitäten eine Aktivität, die die Person identifiziert. Die Ähnlichkeiten der Galerie zu den Modellbildern stecken in den Gewichten $w_{m,g}$

Die Aktivierung des Neurons E lässt sich analog zu [8] berechnen mit

$$A = \sum_{j=1}^K \lambda^{\text{order}(a_j)} w_j. \quad (5)$$

Die Gewichte bestimmen sich aus der präferierten Reihenfolge $\text{order}(a_j)_{\text{max}}$:

$$w_j = \frac{1}{K} \lambda^{\text{order}(a_j)_{\text{max}}}. \quad (6)$$

Das oben beschriebene Ranglistenverfahren vergleicht zwei Bilder anhand von Ranglisten, die die Ähnlichkeit eines Bildes zu Modellbildern widerspiegeln. Stellt man sich vor, dass jeweils ein Neuron a_j zu einer Modellidentität gehört und dass der Rang dem Zeitpunkt des Feuerns dieses Neurons entspricht und dass die zweite Rangliste in den Gewichten w_j kodiert ist, so stellt dieser Schaltkreis die Möglichkeit dar, eine Ranglistenähnlichkeit neuronal zu berechnen. Hierbei nimmt man an, dass das ähnlichste Modellneuron zuerst feuert, und zwar mit einer Verzögerung, die sich aus der Merkmalsähnlichkeit ergibt. Die weitergeleitete Aktivität hängt aber nicht von der vergangenen Zeit ab, sondern nur von der Anzahl der vorher feuernden Neurone. Durch diese Verschaltung wird also automatisch eine Umwandlung von Merkmalsähnlichkeiten in eine Rangliste vorgenommen. Sollte die Entscheidung bereits gefällt werden, obwohl noch nicht alle Neurone gefeuert haben, so haben zumindest diejenigen

gefeuert, die den größten Beitrag liefern. Schaffen es Neurone, ein zweites Mal zu feuern, so ist ihr Beitrag gering, bedingt durch die bis dahin aufgebaute Hemmung, und auch nicht wirklich falsch, da dieser Beitrag ja von den Neuronen stammt, die aufgrund ihres Rangs den größten Beitrag liefern sollen.

Wie erfolgt nun die Verschaltung für die Identifikation? Das Probenbild erzeugt für jedes betrachtete Merkmal eine Rangliste γ_n , im rechten Teil von Abb. 3 durch die Feuerreihenfolge dreier Neurone dargestellt, die zu drei Modellidentitäten gehören. In den Gewichten $w_{m,g,n}$ sind nun die Ranglisten der Galerieidentitäten I_g codiert, gemäß ihrer Ähnlichkeit zu denselben drei mit m indizierten Modellkandidaten:

$$w_{m,g,n} = \frac{1}{N_M} \lambda \gamma_{g,n}^{(m)}. \quad (7)$$

Auf diese Weise ergibt sich die Aktivierung der Neurone A_g aus der Ähnlichkeit der Ranglisten π_n und $\gamma_{g,n}$. Das Neuron mit der größten Aktivierung identifiziert die Person. Die Aktivität A_g , oder anders ausgedrückt, die so definierte Ranglistenähnlichkeit, berechnet sich dabei wie folgt:

$$A_{g,n} = \sum_m \lambda^{\pi_n(m)} w_{m,g,n} \quad (8)$$

$$= \frac{1}{N_M} \sum_m \lambda^{\pi_n(m)} \gamma_{g,n}^{(m)}. \quad (9)$$

Dies ist genau die oben angegebene Ähnlichkeitsfunktion für Ranglisten. Wenn man also davon ausgeht, dass einzelne neuronale Module eine Art Elastisches Graphmatching durchführen können und um so früher feuern, je größer die Ähnlichkeit ist, dann stellt das beschriebene Netzwerk eine neuronale Implementierung der situationsunabhängigen Erkennung dar. In einem parallelen System wäre dies sehr schnell, da die Module nur einen Puls senden müssen, um zu einer korrekten Entscheidung zu kommen.

Experimentelle Ergebnisse

Wir haben die Leistungsfähigkeit des Systems anhand einer großen Datenbank (CAS-PEAL) chinesischer Gesichter getestet [1]. Die Landmarken wurden durch EBGM gefunden, dafür wurden Bilder von 24 Personen von Hand markiert. Aus diesen wurde mit einem automatischen Verfahren [3] für jede Situation ein Bündelgraph erstellt

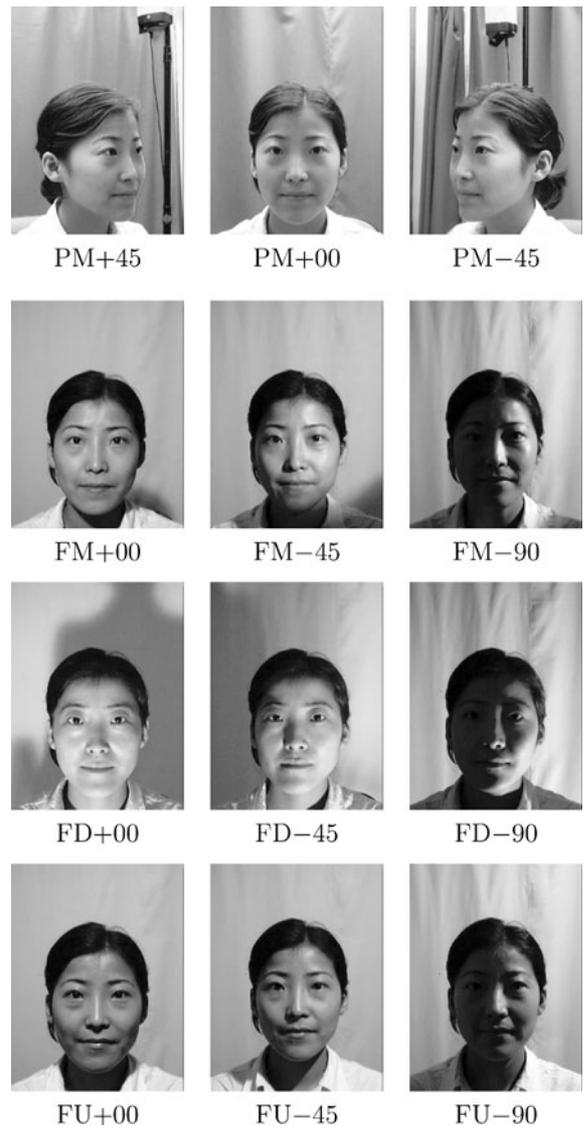


Abb. 4 Beispiele für die Variation der Kopfposen (oben) und Beleuchtung in frontaler Pose in der CAS-PEAL Datenbank

(12 für Pose, 8 für Beleuchtung). Für verschiedene Posen wurden die verbleibenden 1015 Personen zufällig in je eine Modellmenge von 500 und eine Probenmenge von 515 aufgeteilt. Im Beleuchtungsfall waren es 100 für die Modellmenge und 91 für die Probenmenge. Insgesamt wurden 100 verschiedene Partitionen verwendet, um ein Maß für die datenabhängige Variation der Erkennung zu bekommen.

Die Erkennung selbst geschieht wie folgt: Durch einen Vergleich des Probenbildes mit den Bündelgraphen für alle Situationen lässt sich zunächst



Tabelle 1

Erkennungsraten auf der CAS-PEAL Datenbank in Prozent. Die Fehlerintervalle ergeben sich aus 100 zufälligen Partitionierungen in Proben- und Modellmenge

| | Pose | Beleuchtung |
|---|------------|-------------|
| Rate korrekter Situationsschätzung | 99.9 ± 0.1 | 91.7 ± 1.1 |
| Erkennungsrate nach automatischer Situationsschätzung | 97.9 ± 0.5 | 90.1 ± 1.4 |
| Beste Erkennungsrate in der Literatur [2] | 71 | 51 |

In Tab. 1 sind die Ergebnisse aufgeführt. Die starke Verbesserung der Erkennungsleistung gegenüber herkömmlichen Verfahren zeigt, dass die Situation richtig gelernt wurde.

Robustheit des Verfahrens

In einem weiteren Experiment wurde die Erkennungsentscheidung getroffen, bevor überhaupt alle Pulse ausgesendet waren. Das bedeutet, dass die höheren Ränge überhaupt nicht berücksichtigt wurden. Abbildung 5 zeigt, dass die Erkennungsrate schon nach 10 Pulsen sich praktisch nicht mehr verbessert. Sogar bei nur einem einzigen Puls wird noch eine Erkennungsrate von 82,8 % (Pose) bzw. 71,3 % (Beleuchtung) erreicht. Das bedeutet, dass diese Entscheidung in einem neuronalen System sehr schnell fallen kann.

Eine wichtige Frage ist, welche Größe die Modellgalerie haben muss, um die Situation richtig

die wahrscheinlichste Situation ermitteln. Die Ähnlichkeiten des Probenbildes mit den Knoten aller Personen in diesem Bündelgraphen werden dann zu Ranglisten transformiert.

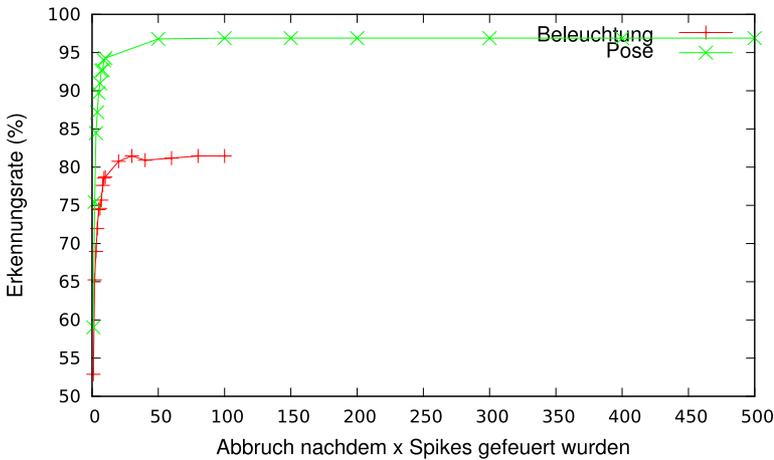


Abb. 5 Erkennungsrate in Abhängigkeit von der Pulsanzahl, die der Berücksichtigung der vorderen Ranglisteneinträge entspricht

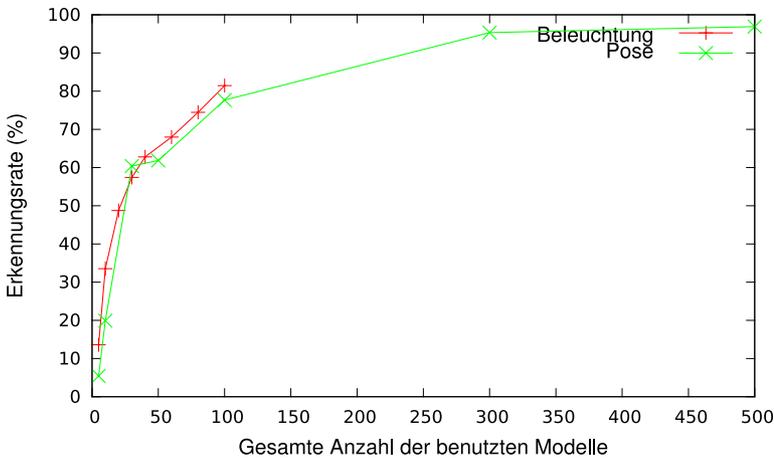


Abb. 6 Abhängigkeit der Erkennung von der Modellgröße

gelernt zu haben. Dafür wurde eine feste Probenmenge von 500 (Pose) bzw. 100 (Beleuchtung) mit Modelldatenbanken verschiedener Größe bearbeitet. Abbildung 6 zeigt, dass für die Pose eine Modellgröße von 300 Personen ausreichend ist, eine weitere Vergrößerung kann die Erkennung nicht mehr verbessern. Im Fall der Beleuchtung stand nicht genug Bildmaterial zur Verfügung, um diese Sättigung zu beobachten. Der etwas steilere Anstieg in diesem Fall lässt jedoch vermuten, dass auch hier etwa 300 Personen ausreichen würden.

Diskussion

Wir haben ein System präsentiert, das die Veränderungen von Gesichtern in verschiedenen Situationen anhand einer begrenzten Anzahl von Personen, die in allen Situationen bekannt sind, lernen kann. Weitere Personen müssen dann nur noch in einer Situation bekannt sein. Das trainierte System erreicht sehr hohe Erkennungsraten bei der Variation von Kopfpose und Beleuchtung.

Dieses System hat den großen Vorteil, dass das Lernen in minimal überwachter Weise erfolgt, es müssen nur die Bilder der Modelldatenbank in verschiedenen Situationen präsentiert werden, mit der zusätzlichen Information, welche davon die gleiche Person zeigen. Das Lernverfahren ist nicht inkrementell, die nötigen Gewichte können direkt aus den Ähnlichkeiten errechnet werden.

Weiterhin kann der Mechanismus durch ein pulsbasiertes neuronales Netzwerk implementiert werden. Im Gegensatz zu vielen neuronalen Modellen ist hier die Information nicht in Pulsfrequenzen,

sondern in der Ankunftszeit einzelner Pulse kodiert. Diese kann in sehr viel kürzerer Zeit ausgewertet werden. Eine massiv parallele Implementierung könnte die Verallgemeinerung über die Situation sehr schnell ausführen. Die kurzen Zeiten für invariante Erkennung im menschlichen Sehsystem im Vergleich zur Signalgeschwindigkeit in Neuronen sind mit frequenzbasierten neuronalen Netzen schwer zu erklären, das hier vorgestellte Modell liefert einen möglichen Mechanismus, der diese Erkennungsgeschwindigkeit erreichen könnte.

Literatur

1. Gao W, Cao B, Shan S, Zhou D, Zhang X, Zhao D (2004) The CAS-PEAL large-scale Chinese face database and baseline evaluations. Technical Report JDL-TR-04-FR-001, Joint Research & Development Laboratory for Face Recognition, Chinese Academy of Sciences, Beijing, China
2. Gao W, Cao B, Shan S, Chen X, Zhou D, Zhang X, Zhao D (2008) The CAS-PEAL large-scale Chinese face database and baseline evaluations. *IEEE T Syst Man Cy A* 38(1):149–161
3. Heinrichs A, Müller MK, Tewes AHJ, Würtz RP (2006) Graphs with principal components of Gabor wavelet features for improved face recognition. In: Cristóbal G, Javidí B, Vallmitjana S (eds) *Information Optics: 5th International Workshop on Information Optics; WIO'06*. American Institute of Physics, pp 243–252
4. Lades M, Vorbrüggen JC, Buhmann J, Lange J, von der Malsburg C, Würtz RP, Könen W (1993) Distortion invariant object recognition in the dynamic link architecture. *IEEE T Comput* 42(3):300–311
5. Müller-Schloer C, von der Malsburg C, Würtz RP (2004) Aktuelles Schlagwort: Organic Computing. *Informatik Spektrum* 27(4):332–336
6. O'Toole AJ, Phillips PJ, Jiang F, Ayyad J, Penard N, Abdi H (2007) Face recognition algorithms surpass humans matching faces over changes in illumination. *IEEE T Pattern Anal* 29:1642–1646
7. Schmeck H, Müller-Schloer C, Çakar E, Mnif M, Richter U (2010) Adaptivity and self-organization in organic computing systems. *ACM Trans Auton Adapt Syst* 5(3):1–32
8. Thorpe S, Delorme A, Van Rullen R (2001) Spike-based strategies for rapid processing. *Neural Networks* 14(6–7):715–725
9. Wiskott L, Fellous J-M, Krüger N, von der Malsburg C (1997) Face recognition by elastic bunch graph matching. *IEEE T Pattern Anal* 19(7):775–779
10. Würtz RP (2005) Organic Computing methods for face recognition. *it – Inform Technol* 47(4):207–211
11. Würtz RP (ed) (2008) *Organic Computing*. Springer