

Automatische Bewertung von Spirogrammen durch Methoden der Mustererkennung

Tobias Schulz

Hochschule für angewandte Wissenschaften Würzburg-Schweinfurt

Der technische Aufwand zur Durchführung von Spirometrie-Messungen ist im Vergleich zu anderen Methoden der Lungenfunktionsdiagnostik relativ gering. Um eine ausreichende Qualität der Spirogramme sicherzustellen, ist jedoch während der Spirometrie eine Anleitung des Patienten durch geschultes Personal notwendig. Eine automatische Qualitätsbewertung kann bei der Beurteilung der Spirogramme unterstützen. So kann es dem Patienten ermöglicht werden, selbstständig, mit Kontrolle durch eine automatische Qualitätsbewertung Spirometrie-Messungen durchzuführen. In dieser Arbeit soll geklärt werden, ob mit Methoden, wie sie in der Mustererkennung angewendet werden, die Qualität von Spirogrammen zuverlässig beurteilt werden kann. Die Beurteilung des Spirogramms findet dabei auf Grundlage von klassifizierten Trainingsdaten statt.

Kategorie und Themenbeschreibung: Software: Mustererkennung

Zusätzliche Schlüsselwörter: Lungenfunktionsdiagnostik, Spirometrie

1 EINLEITUNG

Die Spirometrie stellt eine zentrale Untersuchungsmethode zur frühzeitigen Erkennung von Lungenfunktionsstörungen dar. Gerade für differenzialdiagnostische Untersuchungen stellen spirometrische Messungen, verglichen mit anderen Methoden der Lungenfunktionsprüfung, eine einfach durchzuführende Alternative dar [Bösch und Criée 2009]. Der technologische Fortschritt ermöglicht stetige Verbesserungen der Spirometer hinsichtlich der Benutzerfreundlichkeit sowie der Kompaktheit des Messgeräts. So kann der Patient zuhause oder unterwegs mit mobilen Geräten, ohne Anleitung eines Arztes oder Technikers selbst Spirometrie-Messungen durchführen. Die in digitaler Form aufgezeichneten Spirogramme können später vom Arzt ausgewertet werden.

Spirometrie-Messungen erfordern eine aktive Mitarbeit des Patienten. Der Patient muss unter anderem eine Ausatmung mit maximaler Anstrengung leisten, damit auf Basis des Spirogramms eine aussagekräftige Diagnose erstellt werden kann. Führt der Patient die Messung ohne Anleitung durch geschultes Personal durch, kann die Qualität der Messung nicht

Adresse des Autors:

Tobias Schulz, Hochschule für angewandte Wissenschaften Würzburg-Schweinfurt, Deutschland, Fakultät Informatik und Wirtschaftsinformatik, www.fhws.de.

Die Erlaubnis zur Kopie in digitaler Form oder Papierform eines Teils oder aller dieser Arbeit für persönlichen oder pädagogischen Gebrauch wird ohne Gebühr zur Verfügung gestellt. Voraussetzung ist, dass die Kopien nicht zum Profit oder kommerziellen Vorteil gemacht werden und diese Mitteilung auf der ersten Seite oder dem Einstiegsbild als vollständiges Zitat erscheint. Copyrights für Komponenten dieser Arbeit durch Andere als FHWS müssen beachtet werden. Die Wiederverwendung unter Namensnennung ist gestattet. Es andererseits zu kopieren, zu veröffentlichen, auf anderen Servern zu verteilen oder eine Komponente dieser Arbeit in anderen Werken zu verwenden, bedarf der vorherigen ausdrücklichen Erlaubnis.

sichergestellt werden. Abhilfe schafft eine automatische, computergestützte Bewertung des Spirogramms, die Qualitätsmerkmale automatisch überprüft [Pfüller 2007]. Somit können typische Fehler bei der Durchführung der Spirometrie frühzeitig erkannt werden.

Bisherige Algorithmen zur Qualitätskontrolle von Spirogrammen basieren auf der Anwendung von domänenspezifischem Wissen [Pfüller 2007]. Dazu werden Vitalparameter, wie etwa Lungenvolumen oder Maximalluftstrom, aus den Spirogrammen abgeleitet und auf Plausibilität überprüft. In dieser Arbeit soll untersucht werden, ob eine qualitative Bewertung von Spirogrammen mithilfe von Methoden der Mustererkennung möglich ist. Die Bewertung soll dabei alleine auf einem Vergleich des Spirogramms mit vorgegebenen Trainingsdaten stattfinden.

2 LUNGENFUNKTIONSPRÜFUNG MITTELS SPIROMETRIE

Als Hilfsmittel zur Diagnose von Lungenerkrankungen stehen dem Arzt verschiedene Methoden zur Verfügung. Der Aufwand für eine Untersuchung mittels Spirometrie ist vergleichsweise gering. Andere Methoden der Lungenfunktionsdiagnostik erfordern den Einsatz von technisch komplexeren Messeinrichtungen oder einen höheren Zeitaufwand (z. B. Bodyplethysmographie oder Bronchospasmodolysetestung) [Bösch und Criée 2009]. Im Folgenden werden digitale Spirometrie-Systeme, der Ablauf der Spirometrie-Messung und die Interpretation der daraus gewonnenen Daten, der Spirogramme, beschrieben.

2.1 Digitale Spirometrie-Systeme

Digitale Spirometrie-Systeme messen die Strömungsgeschwindigkeit des Atemluftstroms mit einer konstanten Abtastfrequenz. So wird der Verlauf des Atemluftstroms über eine bestimmte Zeit quantisiert, als Folge digitaler Werte zeitlich äquidistant aufgezeichnet.

Die Abtastfrequenz muss nach dem Nyquist-Shannon-Abtasttheorem mindestens doppelt so hoch sein wie die maximale Frequenz des zu messenden Signals [Smith 2003]. Eine typische Abtastrate von Spirometern, wie auch bei dem in dieser Arbeit verwendeten Gerät, ist 100 Hz.

Zur Umwandlung des Betrags und der Richtung des Luftstroms in digitale Werte haben sich die drei folgenden Messprinzipien durchgesetzt.

Turbine. Der zu messende Luftstrom versetzt das Flügelrad einer Turbine in Bewegung. Aus der Drehzahl des Flügelrades wird die Luftstromstärke berechnet.

Pneumotachograph. Der Luftstrom wird durch eine Verengung mit definiertem Durchmesser geleitet. Vor und hinter der Verengung entsteht proportional zur Stärke des Luftstroms ein Druckunterschied. Drucksensoren messen diese Druckdifferenz. So kann auf Luftstromstärke geschlossen werden.

Ultraschall. Das Ultraschall-Wandler-Messprinzip beruht auf dem Mitnahmeeffekt. Der zu messende Luftstrom beschleunigt oder verringert die Geschwindigkeit von zwei gegenläufigen Ultraschall Impulsen. Aus der Laufzeitdifferenz der beiden Impulse wird auf die Luftstromstärke geschlossen [Fiedler 1992].

Zur Erzeugung von Trainings- und Testdaten wird in dieser Arbeit ein PT (Pneumotachograph)-System verwendet. Systeme nach dem Turbinen-Messprinzip geben die Dynamik des

Luftstroms typischerweise nicht exakt wieder. Die Form der Luftstromkurve wird dadurch verfälscht. Da die Spirogramme auf Basis ihrer Form klassifiziert werden sollen, stellt das PT-System somit die optimale Wahl dar. Durch den Einsatz eines Ultraschall-Systems ergäben sich für diese Arbeit keine weiteren Vorteile.

2.2 Durchführung der Spirometrie

Spirometrie-Messungen sollten unter Anleitung einer geschulten Person vorgenommen werden. Dabei wird der Patient am Spirometer angewiesen, die folgenden Schritte durchzuführen.

- (1) Eine schnelle, maximale Einatmung bis die Lungen vollständig gefüllt sind
- (2) Ein sehr schnelles Ausatmen mit maximaler Kraft
- (3) Weiteres Ausatmen bis die Lungen maximal entleert sind

Der Mund des Patienten muss das Mundstück des Spirometers während diesem Manöver stets fest umschließen. Das Ausatmen muss mit maximaler Anstrengung ausgeführt werden. Die anleitende Person motiviert den Patienten während des Manövers, das Ausatmen mit der nötigen Kraft durchzuführen [Miller et al. 2005].

2.3 Qualitätsbewertung der Spirogramme

Abbildung 1 zeigt beispielhaft drei verschiedene Spirogramme als mögliche Resultate von Spirometrie-Messungen. Die vertikale Achse des Diagramms in Abbildung 1 zeigt die Stärke des Luftstroms an. Zu beachten ist, dass auf die horizontale Achse nicht die Zeit, sondern das Atemvolumen aufgetragen ist. Relevante Abschnitte des Spirogramms lassen sich so besser beurteilen.




Abb. 1: Drei mögliche Resultate einer Spirometrie-Messung: optimaler Verlauf (A), mit Husten- Artefakt (B) und flacher Anstieg wegen zu geringer initialer Anstrengung (C).

Das Spirogramm A in Abbildung 1 zeigt einen idealen Verlauf. Zu Beginn ist deutlich ein steiler Anstieg bis zum maximalen Luftstrom zu erkennen, gefolgt von einem gleichmäßigen Abklingen. Spirogramm B zeigt ebenfalls zu Beginn einen steilen Anstieg, wird jedoch vor Erreichen des maximalen Luftstroms durch ein Artefakt unterbrochen. Solche Artefakte

können beispielsweise durch ein Husten des Patienten entstehen. Spirogramm C weist einen zu flachen Anstieg auf - ein deutlicher Hinweis auf mangelnde Anstrengung des Patienten.

Nicht immer ist eine mangelhafte Qualität so eindeutig zu erkennen, wie bei den Spirogrammen B und C in Abbildung 1. Abweichungen von der idealen Luftstromkurve A können auch Hinweise auf eine Atemwegs- oder Lungenfunktionsstörung sein. Eine gute Qualität des Spirogramms ist daher die Bedingung für eine korrekte Diagnose [Pellegrino et al. 2005].

Diese Arbeit beschränkt sich auf die zwei Arten von Qualitätsmängeln, wie sie in den Spirogrammen B und C in Abbildung 1 dargestellt sind. Die Aufgabe des zu implementierenden Algorithmus ist die korrekte Zuordnung von Spirogrammen in eine der folgenden Klassen:

A Akzeptable Spirogramme

B Spirogramme mit Artefakten

C Hinweise auf mangelnde Mitarbeit

3 AUSWAHL DER TRAININGS- UND TESTDATEN

Die Entscheidung, welcher Klasse ein Spirogramm zugeordnet wird, bestimmt in dem zu implementierenden Mustererkennungs-System der Klassifikator. Dem Klassifikator müssen die Bereiche der Klassen, die er zuordnen soll, bekannt sein. Die Bereiche werden durch klassifizierte Trainingsdaten definiert.

Mit den Testdaten kann die Qualität bzw. die Zuverlässigkeit des Klassifikators, die Klassifikationsrate, überprüft werden. Dazu wird der Anteil der zuvor manuell klassifizierten Testdaten gezählt, die der Klassifikator der korrekten Klasse zuordnet. Test- und Trainingsdaten müssen disjunkt sein [Niemann 1983].

Als Trainingsdaten werden 24 Standard-Testkurven (ATS Spirometry Waveforms (ATS24)) verwendet [o.V. 2014]. Diese Test-Luftstromkurven werden üblicherweise dazu verwendet, die korrekte Funktionsweise von Spirometern zu verifizieren. Bei der Spirometer-Verifikation wird vor allem die korrekte Messung des vorgegebenen Luftstroms und -volumens überprüft [Miller et al. 2005]. Die 24 Standard-Testkurven repräsentieren typische Ergebnisse von Spirometrie-Messungen, darunter auch Spirogramme mit minderer Qualität oder Hinweisen auf Atemwegserkrankungen. Die Testkurven werden mithilfe einer computergesteuerten Pumpe erzeugt und mit einem PT-Spirometer aufgezeichnet. Die so digitalisierten Luftstromkurven werden danach auf einen PC übertragen. Tabelle 1 zeigt die Zuordnung der ATS24-Kurven zu den Klassen aus Abschnitt 2.3, die für diese Arbeit getroffen wurde. Die Zuordnung wurde von einer sachkundigen Person vorgenommen.

Klasse	ATS24-Kurven
A	1,2,3,4,15,17,18,19,21,23,24
B	5,7,8,9,11,20,22
C	6,8,10,12,13,14,16,22

Tab. 1: Die einzelnen ATS24-Kurven wurden von einer sachkundigen Person den Klassen aus Abschnitt 2.3 zugeordnet.

Eine ATS24-Kurve kann der Klasse B und C zugeordnet sein, falls sie Merkmale beider Klassen besitzt. Einige ATS24-Kurven weisen Verläufe auf, die typisch bei Atemwegserkrankungen

sind. Falls jedoch keine Mängel bezüglich der Qualität des Spirogramms erkennbar sind, werden die ATS24-Kurven mit Hinweisen auf Atemwegserkrankungen der Klasse A zugeordnet.

Für die Testdaten werden von verschiedenen Personen jeweils mehrere Spirogramme aufgenommen. Die Probanden werden bei den Messungen aufgefordert, die Spirometrie so durchzuführen, dass Spirogramme entsprechend den Klassen aus Abbildung 1 entstehen. Insgesamt werden 24 Spirogramme von sechs Probanden in die Testdaten aufgenommen. Die Zuordnung der Testdaten zu den Klassen wurde ebenfalls von einer sachkundigen Person vorgenommen.

4 IMPLEMENTIERUNG EINES PROTOTYPS

Abbildung 2 zeigt eine typische Verarbeitungskette, wie sie zur Klassifikation von Mustern eingesetzt wird [Niemann 1983].




Abb. 2: Das System zur Klassifikation der Spirogramme wird in mehrere Module einer Verarbeitungskette aufgeteilt [Niemann 1983].

Das Modul *Aufnahme* in Abbildung 2 bezieht sich auf die Messung der Trainings- und Testdaten, wie in Abschnitt 3 beschrieben. Die weiteren Module werden in den folgenden Abschnitten beschrieben.

4.1 Vorverarbeitung

Bei der Vorverarbeitung werden die Rohdaten so bearbeitet, dass eine Merkmalsgewinnung und Klassifikation erleichtert wird. Ein typisches Verfahren ist z. B. das Entfernen von Störsignalen durch digitale Filter. Eine Filterung der Spirogrammdaten wird bereits durch das verwendete Spirometer-System vorgenommen. Die Vorverarbeitung beschränkt sich deshalb auf die Anpassung der Darstellungsform und die Normierung.

Die Daten des Spirogramms werden als Luftstrom Werte im 10 ms Zeitraster gespeichert. Wertet man diese Daten direkt aus, erhält man eine Fluss-Zeit-Darstellung wie im oberen Diagramm in Abbildung 3. Das mittlere Diagramm in Abbildung 3 zeigt dieselben Daten in Fluss-Volumen-Darstellung. Relevante Bereiche, wie der langsame Anstieg des Luftstroms, sind in der Fluss-Volumen-Darstellung leichter zu erkennen. Das gilt einerseits für die Beurteilung durch Menschen, andererseits auch für die automatische Klassifikation durch die Mustererkennung. Die relevanten Abschnitte nehmen einen größeren Teil des gesamten Musters ein.

Da in dieser Arbeit die Spirogramme alleine aufgrund ihrer Form klassifiziert werden sollen, werden die Informationen der absoluten Luftstrom- und Volumenwerte entfernt. Dies wird durch eine Normierung beider Absolutwerte erreicht. Das untere Diagramm in Abbildung 3

zeigt die normierten Daten des darüber liegenden Spirogramms. Der Luftstrom wird auf den Wert eins, das Luftvolumen auf den Wert 1000 normiert. Die Größe der Spirogramm-Daten beträgt nach der Vorverarbeitung 1000 Datenpunkte. Eine konstante Länge über alle Muster erleichtert die weitere Verarbeitung im Musterkennungs-System.




Abb. 3: Schritte der Vorverarbeitung: Fluss-Zeit-Darstellung (oben), Fluss-Volumen-Darstellung (mittig), Fluss-Volumen-Darstellung normiert (unten).

Normiert man die Spirogramme auf diese Weise, wird ihre ursprüngliche Form verändert. Wesentliche Bereiche der Luftstrom Kurve, wie etwa der zu langsame Anstieg in Abbildung 3, bleiben in der normierten Darstellung erhalten. Der große Vorteil dieses Vorgehens ist, dass Attribute des Patienten, wie etwa Alter oder Geschlecht, nicht berücksichtigt werden müssen. Andere Verfahren zur Auswertung von Spirogrammen verwenden Referenzwerte aus statistischen Erhebungen, um zu überprüfen, ob die erreichten Werte in einem erwarteten Bereich liegen [Pellegrino et al. 2005].

4.2 Merkmale

Die Klassifikation beruht auf der Annahme, dass die Ähnlichkeit zweier Muster aus einer Klasse größer ist, als die Ähnlichkeit von zwei Mustern aus verschiedenen Klassen. Ein quantitatives Maß für die Ähnlichkeit von zwei Mustern kann berechnet werden, indem man Merkmale der Muster als Vektoren betrachtet und den Abstand zwischen beiden Vektoren ermittelt. Elemente des Merkmal-Vektors $\mathbf{c}$ sind dabei numerische Werte, die man aus den Daten des Musters f gewinnt. Der Abstand zwischen zwei Vektoren kann mit der p -Norm aus Formel 1 und $p \in \mathbb{R}^{>0}$ berechnet werden.

$$\|\mathbf{c}_1 - \mathbf{c}_2\|_p = \|\mathbf{c}\|_p := \left(\sum_{i=1}^n |c_i|^p \right)^{1/p} \quad (1)$$

Das Koordinatensystem in Abbildung 4 stellt beispielhaft die Daten von Mustern aus drei beliebigen Klassen dar. Die 30 Kreuz-, Kreis- und Sternsymbole markieren Werte der Muster als

Endpunkte von zweidimensionalen Ortsvektoren f_1 bis f_{30} . Muster, die zu einer Klasse gehören, treten gehäuft an einer Stelle auf. Eine Klassifikation ist in diesem Fall leicht möglich, die Muster sind gut separiert. Als Merkmale können direkt die Daten der Muster übernommen werden ($c_n = f_n$). Abbildung 4 stellt somit zugleich den Merkmalsraum dar.

Aus den Spirogrammen müssen daher Merkmale gewählt werden, die eine möglichst gute Trennung zwischen den Klassen ermöglichen. Ein einfaches Beispiel für Elemente eines zweidimensionalen Merkmals c_{QV} eines Spirogramms wäre etwa der absolute Luftstrom Q und das absolute Luftvolumen V der Luftstromkurve (Formel 2). Eine Klassifizierung nach den gewählten Klassen aus Abschnitt 3 ist mit diesem Merkmal jedoch nicht möglich. Aus den Werten des absoluten Luftstroms und Luftvolumens alleine kann nicht auf die Qualität des Spirogramms geschlossen werden. Außerdem werden diese Informationen durch die Normierung entfernt (vgl. Abschnitt 4.1).

$$c_{QV} = \begin{pmatrix} Q \\ V \end{pmatrix} \quad (2)$$

Eine einfache Übernahme aller 1000 Spirogramm-Datenpunkte in einen Merkmal-Vektor c ist nicht praktikabel. Es ist wünschenswert, dass die gewählten Merkmale eine möglichst niedrige Dimension besitzen. Zum einen wird die zu verarbeitende Datenmenge bei niedrigen Dimensionen geringer. Zum anderen ist eine Abstandsbestimmung nach Formel 1 im hochdimensionalen Raum problematisch. Abhängig von der verwendeten p-Norm verringern sich die Abstände der Merkmale ab einer bestimmten Anzahl an Dimensionen. Die Leistung des Klassifikators kann sich deshalb durch eine Wahl einer höheren Anzahl an Dimensionen verringern [Aggarwal et al. 2001].

Will man bei vorhandenen Merkmalen die Anzahl der Dimensionen verringern, bietet sich ein Vorgehen wie bei den Beispiel-Merkmalen in Abbildung 4 an. Um die Dimensionen von zwei auf eine zu reduzieren, werden die durch Vektoren dargestellten Merkmale mittels Skalarprodukt orthogonal auf den Vektor a projiziert [Teschl 2008]. Die Dreiecksymbole repräsentieren die projizierten zweidimensionalen Vektoren als eindimensionalen Merkmale entlang des Vektors a .




Abb. 4: Beispiel für einen Merkmalsraum und Reduktion der Merkmalsdimensionen: Kreuz- Kreis und Sternsymbole repräsentieren Merkmale im zweidimensionalen Merkmalsraum. Dreiecksymbole repräsentieren die in den eindimensionalen Raum projizierten Merkmale.

Die eindimensionalen Merkmale in Abbildung 4 sind immer noch gut separiert. Merkmale verschiedener Klassen überlagern sich nicht. Vektor $\mathbf{a}$ muss so gewählt werden, dass Merkmale verschiedener Klassen gut getrennt sind. Eine analytische Methode zur Ermittlung des Vektors $\mathbf{a}$ ist die Hauptachsentransformation (engl. PCA (Principal Component Analysis)). Mittels Eigenwert- oder Singulärwertzerlegung erhält man eine Transformationsmatrix $\mathbf{A}$ bzw. den Vektor $\mathbf{a}$. Der mittlere Abstand bzw. die Varianz ist durch die Projektion mit $\mathbf{a}$ maximal. Die Kompaktheit der Merkmale innerhalb der Klassen bleibt dennoch erhalten [Shlens 2003].

Formel 3 zeigt vereinfacht, wie die Hauptachsentransformation im Prototyp benutzt wird. Der erste Eingangsparameter ist für das Beispiel aus Abbildung 4 eine 2×30 Matrix. Der zweite Eingangsparameter m gibt die gewünschte Anzahl der Dimensionen an, auf die die Merkmale reduziert werden. Das Ergebnis ist eine $l \times m$ Transformationsmatrix $\mathbf{A}$ mit l als Länge der Muster-Vektoren $\mathbf{f}$. Für $m = 1$ ist das Ergebnis ein Spaltenvektor $\mathbf{a}$ mit l Elementen. Mit dem Skalarprodukt aus Formel 4 werden die Muster $\mathbf{f}$ in einen m -dimensionalen Merkmalsraum transformiert.

$$PcaMatrix([\mathbf{f}_1 \dots \mathbf{f}_n], m) = \mathbf{A} \quad (3)$$

$$\langle \mathbf{A}, \mathbf{f} \rangle = \mathbf{c} \quad (4)$$

So können die kompletten Datenpunkte eines Spirogramms als Muster-Vektor $\mathbf{f}$ interpretiert und mittels der Transformationsmatrix $\mathbf{A}$ auf Merkmale mit einer beliebigen Anzahl an Dimensionen m reduziert werden. $\mathbf{A}$ wird dabei mithilfe der Trainingsdaten, den ATS24-Kurven, berechnet. Je nach Zuverlässigkeit des Klassifikators kann die verwendete Anzahl an Dimensionen angepasst werden.

4.3 Stichprobe und Lernen

Ziel des Lernens ist es, den Klassifikator so zu parametrieren, dass er Merkmal-Vektoren von Mustern den richtigen Klassen zuordnet. Für die Merkmal-Vektoren in Abbildung 4 lassen sich leicht Klassengrenzen definieren, etwa durch drei Dichtefunktionen der Normalverteilung mit Mittelwerten im Zentrum der jeweiligen Merkmal-Wolken. Die Varianzen lassen sich ebenfalls für jede Klasse aus den Daten der jeweiligen Merkmale schätzen. Durch die Position eines zu klassifizierenden Merkmals im Merkmalsraum lässt sich so die Wahrscheinlichkeit der jeweiligen Klassenzugehörigkeit berechnen. Die zu lernenden Parameter wären in diesem Fall die Mittelwerte und Varianzen für jede Klasse. Beim überwachten Lernen können diese Parameter anhand einer Stichprobe von klassifizierten Mustern bzw. den Trainingsdaten geschätzt werden [Niemann 1983].

Abbildung 5 zeigt die Merkmal-Vektoren der Trainingsdaten nach der Hauptachsentransformation in einem dreidimensionalen Merkmalsraum. Die Klassengrenzen lassen sich nicht durch einfache Dichtefunktionen von Wahrscheinlichkeitsverteilungen definieren. Die Klassengrenzen sind ineinander verzahnt. Die ATS24-Kurven, welche als Trainingsdaten dienen, weisen pro Kurve oft Eigenschaften von mehreren der in Tabelle 1 aufgeführten Klassen auf.

Für die Klassifikation der Spirogramme wird ein nichtparametrisches Klassifikationsverfahren, die Nearest-Neighbor-Klassifikation gewählt. Somit müssen keine Parameter durch Lernen ermittelt werden, die Lernphase entfällt. Ein weiterer Vorteil dieses Klassifikators ist außerdem, dass komplexe Klassengrenzen wie in Abbildung 5 nicht durch eine parametrische Funktion beschrieben werden müssen.




Abb. 5: Dreidimensionale Merkmale der ATS24-Kurven nach der Hauptachsentransformation: Die Merkmale der drei Klassen A, B und C können nur durch komplexe Klassengrenzen voneinander separiert werden. Merkmale, die mehreren Klassen zugeordnet sind, werden hier nicht abgebildet. Für die Trainingsdaten wurde jede der ATS24-Kurven mehrfach aufgezeichnet. Deshalb sind mehr als 24 Datenpunkte abgebildet.

4.4 Klassifikation

Der Nearest-Neighbor-Klassifikator (NN) geht davon aus, dass ein Merkmal von Merkmalen derselben Klasse umgeben ist. Um die Klasse eines Merkmals zu bestimmen, wird der Abstand des Merkmals zu allen bekannten und klassifizierten Merkmalen der Trainingsdaten berechnet. Das zu klassifizierende Merkmal wird derselben Klasse zugeordnet, welche das Trainingsdaten-Merkmal mit dem geringsten Abstand besitzt. Es können auch mehrere nächste Nachbarn gesucht werden und eine Mehrheitsentscheidung getroffen werden. Bei der geringen Anzahl an Trainingsdaten, die für diese Arbeit zur Verfügung stehen, ist eine Mehrheitsentscheidung jedoch nicht sinnvoll.

Der NN-Klassifikator erlaubt beliebig komplexe Klassengrenzen. Allerdings müssen die Merkmale aller Trainingsdaten gespeichert werden. Bei jeder Klassifikation muss zudem der nächste Nachbar in den gesamten Trainingsdaten durch Abstandsbestimmung ermittelt werden. Die Laufzeitkomplexität der NN-Suche $O(n \cdot m)$ steigt mit der Anzahl der Trainingsdaten n und deren Anzahl an Dimensionen m . Geeignete Datenstrukturen ermöglichen bei größeren Mengen an Trainingsdaten eine effiziente Suche [Shibata et al. 2003].

5 ERGEBNISSE

Für die Bewertung des Prototyps wird der Anteil vom Klassifikator richtig zugeordneten Merkmal-Vektoren c aus den Testdaten zur korrekten Klasse betrachtet ($c_k \rightarrow \kappa$). Test- und Trainingsdaten sind zuvor von einer sachkundigen Person den Klassen A, B und C zugeordnet worden ($\kappa \in \{A, B, C\}$, vgl. Abschnitt 3). Die Klassifikationsrate gibt den Anteil der vom Prototypen korrekt zugeordneten Mustern an. Außerdem wird die Zuverlässigkeit des Klassifikators in Abhängigkeit von der Anzahl der Merkmaldimension und der verwendeten p-Norm gemessen (vgl. Formel 1). Abbildung 6 zeigt die Ergebnisse der Klassifikation der Testdaten durch den Prototyp.




Abb. 6: Klassifikationsrate des Prototyps: Die Klassifikationsrate steigt bei zunehmender Anzahl an Dimensionen, abhängig von der verwendeten p -Norm.

Erwartungsgemäß erhöht sich der Anteil der richtig zugeordneten Spirogrammen mit der Anzahl der Merkmalsdimensionen. Bei der Verwendung der p -Norm mit $p = 0,3$ entsteht ein Optimum von 92% bereits bei 10 Merkmalsdimensionen. Die höchste Klassifikationsrate von 96% wird für $p = 0,8$ ab 20 Merkmalsdimensionen erreicht, es wird lediglich ein Spirogramm der Testdaten falsch zugeordnet.

6 FAZIT

Die Ergebnisse aus Abbildung 6 zeigen, dass sich bereits durch das Prototypen-System hohe Trefferquoten erzielen lassen. Der Klassifikator ordnet bis zu 23 von 24 Testdaten korrekt zu. Somit kann ein solches System Unterstützung bieten, falls Spirogramme von dem Patienten als Laien selbstständig aufgenommen werden. Die Wahrscheinlichkeit, dass Spirometrie-Messungen mit zu wenig initialer Anstrengung oder Artefakten erkannt werden, liegt bei 96%. Das Spirometrie-System kann den Patienten daraufhin auffordern, die Messung zu überprüfen bzw. zu wiederholen. Ein weiterer Einsatz wäre bei der automatischen Vorauswahl bei einer größeren Menge von Spirogrammen denkbar. Wie etwa bei der Durchführung medizinischer Studien. Weiterhin hat sich bei der Arbeit mit den Testdaten gezeigt, dass ebenfalls eine Klassifikation nach einer Atemwegsobstruktion möglich ist. Testdaten mit leichten Hinweisen einer solchen Einengung der Atemwege konnten den entsprechenden Trainingsdaten zugeordnet werden. Für eine valide Auswertung der Spirogramme im Prototyp bezüglich einer Obstruktion lagen jedoch nicht ausreichend Testdaten mit diesem Krankheitsbild vor.

Abbildung 5 in Abschnitt 4.3 zeigt, dass die gewählten Merkmale der Trainingsdaten nicht optimal separiert sind. Durch die komplexen Klassengrenzen ist die Auswahl an Klassifikatoren deutlich eingeschränkt. In den verwendeten Trainingsdaten, den ATS24-Testkurven, treten in vielen Spirogrammen Merkmale verschiedener der in dieser Arbeit verwendeter Klassen auf. Außerdem entspricht die Aufzeichnungsqualität der ATS24-Testkurven nicht dem aktuellen Stand der Technik [Reinstädler 2012]. Eine bessere Klassentrennung lässt sich evtl. durch eine gezielte Wahl bzw. Generierung von Trainingsdaten erreichen. Somit könnte ein Klassifikator mit geringerer Laufzeit- und Speicherkomplexität als der NN-Klassifikator verwendet werden. Dies würde eine effiziente Implementierung auf Embedded-Systemen mobiler Spirometer ermöglichen.

LITERATUR

Charu C. Aggarwal, Alexander Hinneburg, und Daniel A. Keim. 2001. On the Surprising Behavior of Distance Metrics in High Dimensional Space. In Database Theory — ICDT 2001, Jan Bussche and Victor Vianu (Bearbeiter). Lecture Notes in Computer Science, Band 1973. Springer Berlin Heidelberg, Berlin und Heidelberg, 420–434. DOI:http://dx.doi.org/10.1007/3-540-44503-X_27

o.V. 2014. American Thoracic Society Spirometry Waveforms. (2014). Zuletzt aufgerufen am 03.05.2014 von <http://www.thoracic.org/education/pulmonary-function-testing/spirometry-waveforms/index.php>

Dennis Bösch und Carl-Peter Criée. 2009. Lungenfunktionsprüfung: Durchführung - Interpretation - Befundung (2. Auflage). Springer Medizin, Heidelberg.

Otto Fiedler. 1992. Strömungs- und Durchflussmesstechnik. Oldenburg, München und Wien.

M. R. Miller, J. Hankinson, V. Brusasco, F. Burgos, R. Casaburi, A. Coates, R. Crapo, P. Enright, van der Grinten, C P M, P. Gustafsson, R. Jensen, D. C. Johnson, N. MacIntyre, R. McKay, D. Navajas, O. F. Pedersen, R. Pellegrino, G. Viegi, und J. Wanger. 2005. Standardisation of spirometry. The European respiratory journal 26, 2 (2005), 319–338. DOI:<http://dx.doi.org/10.1183/09031936.05.00034805>

Heinrich Niemann. 1983. Klassifikation von Mustern. Springer, Berlin.

R. Pellegrino, G. Viegi, V. Brusasco, R. O. Crapo, F. Burgos, R. Casaburi, A. Coates, van der Grinten, C P M, P. Gustafsson, J. Hankinson, R. Jensen, D. C. Johnson, N. MacIntyre, R. McKay, M. R. Miller, D. Navajas, O. F. Pedersen, und J. Wanger. 2005. Interpretative strategies for lung function tests. The European respiratory journal 26, 5 (2005), 948–968. DOI:<http://dx.doi.org/10.1183/09031936.05.00035205>

Mark Pfüller. 2007. Validierung eines Algorithmus zur automatischen Qualitätskontrolle spirometrischer Fluss-Volumen-Kurven und Messgrößen. (2007). Zuletzt aufgerufen am 25.03.2014 von http://edoc.ub.uni-muenchen.de/7778/1/Pfueller_Mark.pdf

Jürgen Reinstädter. 2012. How Physiological Are The ATS Flow/Volume-Loop Waveforms? In A66. MODELING, MECHANICS AND GAS EXCHANGE. Band 185. A2087–A2087. DOI:http://dx.doi.org/10.1164/ajrccm-conference.2012.185.1_MeetingAbstracts.A2087

T. Shibata, T. Kato, und T. Wada. 2003. K-d decision tree: an accelerated and memory efficient nearest neighbor classifier. In Third IEEE International Conference on Data Mining. 641–644. DOI:<http://dx.doi.org/10.1109/ICDM.2003.1250997>

Jonathon Shlens. 2003. A Tutorial On Principal Component Analysis. (2003). Zuletzt aufgerufen am 03.05.2014 von http://www.cs.princeton.edu/picasso/mats/PCA-Tutorial-Intuition_jp.pdf Steven W. Smith. 2003. Digital signal processing: A practical guide for engineers and scientists. Newnes, Amsterdam.

Gerald Teschl. 2008. Mathematik für Informatiker (3. Auflage). eXamen.press, Band 1. Springer, Berlin und Heidelberg und New York.

