

10. Clusteranalyse

Abschließend soll noch ein Blick auf die Möglichkeit geworfen werden, langfristige Temperaturvorhersagen mittels Clusteranalyse zu erstellen. Wird diese Methodik zu prognostischen Zwecken eingesetzt, so weist sie große Parallelen zu den Analogverfahren auf. Es existieren jedoch auch einige gravierende Unterschiede, die zu der Hoffnung veranlassen, daß sich die durch analoge Techniken zu erzielende Vorhersageleistung steigern läßt.

Grundprinzip der Clusteranalyse ist es, die einzelnen Beobachtungen eines vorliegenden Datensatzes derart in Gruppen (Cluster) zu sortieren, daß gruppeninterne Ähnlichkeiten maximiert werden, während die Ähnlichkeiten zwischen den verschiedenen Clustern minimiert werden (*Balling*, 1984). Dabei ergeben sich sowohl die Zuordnung der einzelnen Beobachtungen als auch die Anzahl der unterschiedlichen Cluster allein an Hand des verwendeten Datenmaterials. Bei den Einzelbeobachtungen handelt es sich um Vektoren, d.h. es werden multivariate Datensätze wie z.B. Feldverteilungen untersucht. Die Anwendungsmöglichkeiten im Bereich der Klimatologie sind daher vielfältig, so nutzten z.B. *Fovell und Fovell* (1993) die Clusteranalyse, um die Klimazonen der USA auf der Basis meteorologischer Meßwerte zu definieren.

Im Gegensatz zur vergleichbaren Diskriminanzanalyse liefert die Clusteranalyse keine Zuordnungsvorschrift für künftige Beobachtungen. Um sie dennoch zur Langfristprognose einsetzen zu können, muß sie für jede anstehende Vorhersage wiederholt werden. Das Vorhersageprinzip ist dabei denkbar einfach: Für die aktuellen Beobachtungen der als Einflußgrößen verwendeten Variablen (im Rahmen dieser Arbeit also Feldverteilungen des Luftdrucks) wird zusammen mit denen eines historischen Datenarchivs zunächst eine Clusteranalyse durchgeführt. Die Vorhersage ergibt sich dann aus den in der Vergangenheit eingetretenen Werten der Zielgröße (hier monatliche Temperaturanomalien) derjenigen Jahre, die demselben Cluster angehören wie der aktuelle Fall. Auf Grund des relativ geringen Umfanges der einzelnen Cluster bietet sich hier in der Regel nur die Verwendung des Mittelwertes an.

Der wichtigste Unterschied zu den Analogverfahren liegt in der Art und Weise, wie die Analoga bestimmt werden. Dadurch, daß die Clusteranalyse ohne die Vorgabe einer festen Anzahl analoger Fälle bzw. ohne die Festsetzung einer mehr oder weniger willkürlichen Analogieschwelle auskommt, entstehen natürlichere Kollektive. Das Risiko, daß durch Zwangszuweisung zugeordnete Fälle die Kollektive verfälschen, wird deutlich verringert. Dies drückt sich allein schon in der Tatsache aus, daß die Anzahl der den einzelnen Clustern zugewiesenen Beobachtungen beliebig variieren kann und von Cluster zu Cluster nicht gleich sein muß. Damit wird die Clusteranalyse den Verhältnissen in der Realität sicherlich eher gerecht als die Analogverfahren. Ist es doch viel wahrscheinlicher, daß sich ein Datenarchiv aus einigen eher seltenen und vielen häufiger auftretenden Wetterlagen zusammensetzt, als daß sich in allen Fällen etwa gleich viele Analoga finden lassen.

Auch an dieser Stelle soll auf eine umfassende Erläuterung der Methodik verzichtet werden. Denjenigen Lesern, die auf eine ausführlichere Einführung in das Gebiet Wert legen, sei die Darstellung von *Wilks* (1995) empfohlen. Eine Beurteilung der Leistungsfähigkeit dreier gängiger Techniken zur Durchführung einer Clusteranalyse findet man bei *Kalkstein et al.* (1987). U.a. der Frage, wie im Falle untereinander korrelierter Eingangsvariablen zu verfahren ist, widmen sich *Mimmack et al.* (2001). Hier findet man auch eine Alternative zum normalerweise verwendeten Abstandsmaß, der euklidischen Distanz.

10.1 Mathematisch-statistische Grundlagen

Grundsätzlich unterscheidet man agglomerierende und trennende sowie hierarchische und kernartige Clusteranalysen. Agglomerierende Clusteranalysen fügen die einzelnen Beobachtungen zu Gruppen zusammen, während trennende Clusteranalysen die vollständige Stichprobe in kleinere Gruppen zerlegen. Bei hierarchischen Clusteranalysen wird eine Hierarchie von Gruppensätzen gebildet, indem zwei Gruppen einer Analysestufe in einer höheren Stufe zusammengefügt werden, während der Datensatz bei kernartigen Clusteranalysen stark differenziert ist und die unterschiedlichen Cluster bereits vorab ersichtlich sind.

Die überwiegende Zahl gängiger Clusteranalysetechniken sind agglomerierend und hierarchisch. Man beginnt die Prozedur mit der Annahme, daß die n Beobachtungen des k Komponenten umfassenden Datenvektors \mathbf{x} keinerlei Gruppenstruktur unterliegen, d.h. man hat n Cluster mit jeweils einem Mitglied. In der ersten Stufe der Analyse sucht man nun jene zwei Gruppen, d.h. Datenvektoren \mathbf{x} , die den kleinsten Abstand aller Gruppen untereinander im k -dimensionalen Raum aufweisen. Diese beiden Gruppen werden zu einem neuen Cluster zusammengefügt, wodurch sich die Anzahl der Cluster auf $n-1$ verringert. In jeder weiteren Analysestufe werden nun erneut diejenigen zwei Gruppen miteinander verschmolzen, die den kleinsten Abstand zueinander aufweisen. Nach der letzten, d.h. der $(n-1)$ sten Stufe, sind dann sämtliche Beobachtungen in nur einem Cluster zusammengefaßt worden.

Der entscheidende Schritt im Verlaufe der Analyse ist es nun, diejenige Stufe festzulegen, nach welcher die Prozedur abubrechen ist. Man hofft, daß sich zu einem gewissen Zeitpunkt eine intuitive, d.h. natürliche, Gruppierung der Daten derart ergibt, daß man eine bearbeitungsfähige Anzahl verschiedener Cluster erhält (siehe dazu auch Abschnitt 10.2).

Ebenfalls von großer Bedeutung ist die Wahl des Distanzmaßes. Je nachdem wie man den Abstand zweier Datenpunkte definiert, können sich die Ergebnisse einer Clusteranalyse u.U. erheblich voneinander unterscheiden. Allgemein herrscht keine Einigkeit darüber, welches Distanzmaß am geeignetsten ist, jedoch besitzen alle in der Literatur verwendeten Maße die drei unten aufgeführten Eigenschaften. Sei d_{ij} der Abstand der Punkte \mathbf{x}_i und \mathbf{x}_j im k -dimensionalen Raum, dann gelten:

1. Der Abstand zwischen \mathbf{x}_i und \mathbf{x}_j ist exakt gleich dem Abstand zwischen \mathbf{x}_j und \mathbf{x}_i , d.h. $d_{ij} = d_{ji}$.
2. Allgemein kann der Abstand keine negativen Werte annehmen, d.h. $d_{ij} \geq 0$.
3. Der Abstand zwischen \mathbf{x}_i und \mathbf{x}_i ist gleich Null, d.h. $d_{ii} = 0$.

In der Regel wird zusätzlich gefordert, daß es sich bei dem verwendeten Distanzmaß um eine metrische Größe handelt, wodurch zwei weitere Eigenschaften hinzu kommen:

4. Ist der Abstand zwischen \mathbf{x}_i und \mathbf{x}_j gleich Null, so müssen auch \mathbf{x}_i und \mathbf{x}_j gleich sein, d.h. $d_{ij} = 0$ gilt nur für $\mathbf{x}_i = \mathbf{x}_j$.
5. Die Länge einer der Seiten eines durch drei beliebige Punkte aufgespannten Dreiecks kann nicht größer sein als die Länge der übrigen beiden Seiten zusammen, d.h. $d_{ij} \leq d_{il} + d_{jl}$.

Im klimatologischen Anwendungsbereich wird heutzutage hingegen vorwiegend die sogenannte euklidische Distanz benutzt (Mimmack *et al.*, 2001). Sie gibt den kürzesten Abstand zwischen zwei Punkten im geometrischen Raum an und ist zusätzlich zu den fünf genannten Eigenschaften invariant gegenüber orthogonalen Transformationen:

$$d_{ij} = |\bar{x}_i - \bar{x}_j| = \left[\sum_{l=1}^k (x_{il} - x_{jl})^2 \right]^{\frac{1}{2}}. \quad (10.1)$$

Läßt sich der Abstand zweier Datenpunkte eindeutig festlegen, so gilt dies für die Distanz zwischen Clustern, die mehrere Mitglieder enthalten, nicht. Vielmehr existiert eine Vielzahl denkbarer Möglichkeiten den Abstand zwischen den einzelnen Gruppen von Punkten zu definieren. Die Wahl dieses Kriteriums bestimmt im wesentlichen die Art der Clusteranalyse. Im folgenden sollen die drei gebräuchlichsten Methoden kurz vorgestellt werden.

Bei der als „average-linkage“ bezeichneten Methode wird die Distanz zweier Cluster als Mittelwert sämtlicher Abstände zwischen allen möglichen Punktpaaren beider Gruppen (jeweils ein Punkt pro Cluster) definiert. Enthalten die Cluster C_1 und C_2 n_1 bzw. n_2 Datenpunkte, so ergibt sich für die Distanz beider Gruppen der Wert

$$d_{C_1 C_2} = \frac{1}{n_1 n_2} \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} d_{ij}. \quad (10.2)$$

Der Algorithmus, welcher als „centroid method“ bekannt ist, definiert den Abstand zweier Cluster als Distanz zwischen den jeweiligen Vektormitteln beider Punktgruppen. Es werden sozusagen die Zentren der betrachteten Cluster zur Festlegung der Entfernung verwendet. Dementsprechend gilt:

$$d_{C_1 C_2} = |\bar{x}_{C_1} - \bar{x}_{C_2}|, \quad \text{mit}$$

$$\bar{x}_c = \begin{bmatrix} \frac{1}{n_c} \sum_{i=1}^{n_c} x_{i1} \\ \frac{1}{n_c} \sum_{i=1}^{n_c} x_{i2} \\ \vdots \\ \frac{1}{n_c} \sum_{i=1}^{n_c} x_{ik} \end{bmatrix}, \quad c = 1, 2. \quad (10.3)$$

Hierin ist n_c die Anzahl der Mitglieder des jeweiligen Clusters. Die Vektormittel sind also definiert als diejenigen Vektoren, deren k te Komponente den jeweiligen Mittelwert der k ten Komponente der Datenvektoren \mathbf{x} des entsprechenden Clusters enthalten.

Ziel der **Ward's minimum variance method** ist es, in jeder Analysestufe die Summe der quadratischen Abweichungen aller Gruppenmitglieder vom jeweiligen Vektormittel sämtlicher Cluster zu minimieren. Existieren also $m(m-1)/2$ verschiedene Möglichkeiten um zwei von insgesamt m Clustern derart zu vereinen, daß $m-1$ Cluster resultieren, so wird stets diejenige Vereinigung durchgeführt, die den Wert

$$W = \sum_{l=1}^{m-1} \sum_{i=1}^{n_c} |\bar{x}_i - \bar{x}_l|^2 = \sum_{l=1}^{m-1} \sum_{i=1}^{n_c} \sum_{j=1}^k (x_{ij} - \bar{x}_{lj})^2 \quad (10.4)$$

minimiert. Der Wert W ist also für sämtliche $m(m-1)/2$ Möglichkeiten gesondert zu berechnen, wobei darauf zu achten ist, daß das Zentrum des jeweils neu geformten Clusters aus den Daten beider zuvor getrennten Cluster zu bestimmen ist, bevor die quadratischen Abstände berechnet werden. Dementsprechend ist die Methode äußerst rechenintensiv.

Aus Gleichung 10.4 geht hervor, daß die Methode von **Ward** nicht die euklidische Distanz (Gl. 10.1), sondern grundsätzlich deren Quadrat verwendet, wodurch die unter 5. oben aufgeführte Eigenschaft verloren geht. Dies gilt natürlich auch dann, wenn eine der anderen beiden Methoden statt mit der euklidischen Distanz mit ihrem Quadrat durchgeführt wird. Dennoch konnten *Kalkstein et al.* (1987) zeigen, daß insbesondere im Falle des „average-linkage“ eine Anwendung des Quadrats der Gleichung 10.1 ebenfalls sehr zufriedenstellende Ergebnisse liefert (siehe auch Abschnitt 10.3).

10.2 Anzahl der Cluster

Ebenso wie mehrere verschiedene Regeln zur Bestimmung der Anzahl beizubehaltender Hauptkomponenten im Falle der EOF-Analyse existieren (vergl. Abschnitt 9.2), gibt es unterschiedliche Ansätze zur Festsetzung der finalen Stufe einer Clusteranalyse. Derartige Orientierungsregeln sind notwendig, da die „richtige“ Anzahl von Clustern nur selten offensichtlich ist.

Ein verbreitete Methode ist die Festlegung der Abbruchstufe an Hand einer graphischen Darstellung der Distanzen zwischen den jeweils vereinigten Clustern als Funktion der Analysestufe. Ein Beispiel für einen derartigen Plot ist in Abbildung 10.1 zu finden. Sie zeigt die Distanzen, die sich für eine Clusteranalyse der Bodendruckfelder der Monate Januar 1909-1998 ergeben haben. Als Eingangsvariablen dienten dabei nicht die Gitterpunktwerte selbst, sondern die wichtigsten Hauptkomponenten der Feldverteilung (vergl. Abschnitt 10.3). Zu Beginn der Analyse werden stets sehr ähnliche Cluster vereinigt, so daß die Abstände klein sind und nur langsam anwachsen. Am Ende der Prozedur sind hingegen nur noch wenige Cluster vorhanden, die durch große Abstände voneinander getrennt sind. Ist eine Stufe auszumachen, in welcher die Distanz zwischen den zusammengefaßten Clustern einen markanten Sprung macht, so ist die Analyse unmittelbar vor dieser Stufe zu beenden. Dabei kommt es auch bei dieser Vorgehensweise immer wieder vor, daß mehrere Stellen als Abbruchpunkt in Frage kommen, was die Subjektivität der Methode ausmacht. So wären an Hand der

Abbildung 10.1 theoretisch zumindest vier Stellen denkbar gewesen: nach der Stufe 53, 57, 68 bzw. 82. Den Ausschlag dafür, daß letztlich erst nach der 82. Stufe abgebrochen wurde, gab die Anzahl der resultierenden Cluster, die ansonsten unerwünscht groß ausgefallen wäre.

Objektive Methoden auf der Basis von Monte-Carlo-Simulationen (speziell bootstrap) existieren ebenfalls, wurden jedoch im Rahmen dieser Arbeit nicht verwendet und sollen daher nicht näher vorgestellt werden.




Abbildung 10.1: Ergebnisse einer Clusteranalyse der Monate Januar des Zeitraums 1909-1998 basierend auf den wichtigsten Hauptkomponenten der Bodendruckverteilung der Nordhalbkugel.

10.3 Vorgehensweise

Um die größtmögliche Anzahl unterschiedlicher Cluster mit einer vernünftigen Besetzungszahl erzielen zu können, d.h. die bestmögliche Differenzierung gewährleisten zu können, wurde für diese Untersuchung wieder auf den 90-jährigen Datensatz „ds010.1“ von NCAR zurückgegriffen. Dementsprechend beschränken sich die Clusteranalysen der Basismonate t_0 auf die Bodendruckfelder mit den entsprechenden Datenlücken (siehe Abb. 2.1). Hierdurch wird zusätzlich die uneingeschränkte Vergleichbarkeit der Leistungsfähigkeit von Clusteranalyse und Analogverfahren sichergestellt.

Die zur Abschätzung des Leistungsvermögens der Methodik angewendete Vorgehensweise läßt sich im wesentlichen als eine Kombination der im Falle der PCR und der Analogverfahren gewählten Verfahrensweisen beschreiben (vergl. die Abschnitte 9.3 bzw. 8.2.1, 8.3.1, 8.4.1 sowie 8.5.1): In einem ersten Schritt wurde für jeden Kalendermonat eine gesonderte Clusteranalyse für die Feldverteilungen des Bodendrucks des Zeitraums 1909-1998 durchgeführt, d.h. die Stichproben umfassen je $n=90$ Beobachtungen. Auf diese Weise wurde das Datenarchiv also in Gruppen ähnlicher Zirkulationsformen eingeteilt, so daß die Mitglieder eines einzelnen Clusters

sozusagen analoge Fälle füreinander darstellen. Die Temperaturvorhersagen für die folgenden Monate ergeben sich nun nach demselben Muster wie im Falle der Analogverfahren. Es wurde von der Annahme ausgegangen, daß sich die Witterung in einer zu den anderen Mitgliedern des Clusters vergleichbaren Weise weiterentwickelt, weswegen schlicht der Mittelwert der Folgetemperaturen aller übrigen Clustermitglieder vorhergesagt wurde. Umfaßte ein Cluster jedoch weniger als vier Jahre, so wurde der vieljährige Klimamittelwert vorhergesagt. Auf diese Weise sollte der Einfluß von Ausreißern minimiert werden. Als maximale Vorlaufzeit wurden hier sechs Monate gewählt.

Wie schon im Falle des „VAMs“ und der PCR muß trotz trendbereinigter Daten und durchgeführter Cross-Validation erneut von einer zu optimistischen Schätzung der Vorhersageleistung ausgegangen werden. Grund hierfür ist die Tatsache, daß die Clusteranalysen pro Kalendermonat nur einmal durchgerechnet wurden, wobei jeweils die vollständigen Stichproben benutzt wurden. Die Druckdaten des im Rahmen der Cross-Validation (U-Methode) jeweils als Examinationskollektiv verwendeten Jahres wurden daher bei der Analyse stets mit berücksichtigt, wodurch dessen vollständige Unabhängigkeit verloren geht (siehe dazu auch die Abschnitte 8.5.1 sowie 9.3). Der Grad der Überschätzung dürfte dabei sogar noch höher ausfallen als bei den beiden anderen Verfahren, da sich der komplette Verlauf einer Clusteranalyse ändern kann, wenn eine Eingangsbeobachtung zurückbehalten wird. Dies kann im Extremfall eine vollständig andere Zusammensetzung der Cluster zur Folge haben. Dennoch wurde darauf verzichtet, die Clusteranalysen für jedes zu verifizierende Jahr zu wiederholen, da der Arbeitsaufwand insbesondere auf Grund der graphischen Bestimmung der Clusteranzahl (siehe Abschnitt 10.2) ein akzeptables Maß bei weitem überschritten hätte.

Als Eingangsvariablen für die durchgeführten 12 Clusteranalysen dienten nicht die Monatsmittelwerte des Bodendrucks an den 389 vorhandenen Gitterpunkten selbst, sondern die wichtigsten Hauptkomponenten dieser Feldverteilungen. Dadurch wurde eine Überbewertung aller untereinander korrelierter Gitterpunkte vermieden, wie es bei einer Clusteranalyse mit den ursprünglichen Daten der Fall gewesen wäre. Dieser Umstand stellt einen weiteren Vorteil zu den hier getesteten Analogverfahren dar, wo die Originaldaten zur Bestimmung der analogen Fälle verwendet wurden. Das Risiko, daß die Wahl der „analogen Fälle“ von der geographischen Lage der vorhandenen Gitterpunktwerte abhängt, wird im Vergleich zum „VAM“ noch einmal verringert (vergl. Abschnitt 8.5.1).

Die Berechnung der Hauptkomponenten erfolgte auf dieselbe Art und Weise wie im 9. Kapitel, d.h. es wurden die EOFs der Korrelationsmatrizen bestimmt. Lediglich bei der Beschneidung der Hauptkomponenten wurde hier die **Kaiser's rule** (Gl. 9.9) verwendet, um somit eine verhältnismäßig große Anzahl der neuen Variablen beizubehalten. Führt man eine Clusteranalyse mit zu wenigen Hauptkomponenten durch, so kann es vorkommen, daß Beobachtungen, die sich nur an Hand von Hauptkomponenten höherer Ordnung unterscheiden lassen, fälschlich in einem Cluster zusammengefaßt werden. Daher ist es besser, irrtümlich einige Hauptkomponenten zuviel beizubehalten (*Mimmack et al.*, 2001).

Wie ein Blick auf Tabelle 10.1 verdeutlicht, ist durch die Anwendung der **Kaiser's rule** praktisch sichergestellt, daß keine bedeutenden Informationen verloren gegangen sind. Die je nach Kalendermonat beibehaltenen 27-38 Hauptkomponenten repräsentieren in allen Fällen etwa 96% der Gesamtvarianz der Originaldaten. Auf Grund der mit Sicherheit existierenden Interkorrelationen zumindest einiger Gitterpunkte ist es höchst

unwahrscheinlich, daß die übrigen ca. 4% nicht dem Rauschanteil angehören. Wurde hingegen ein Teil des Rauschens mit berücksichtigt, so bleibt der Vorteil, daß die Hauptkomponenten untereinander unkorreliert sind, dennoch bestehen.

Jan	Feb	Mar	Apr	Mai	Jun	Jul	Aug	Sep	Okt	Nov	Dez
27	27	28	33	36	37	38	37	37	35	31	29
96,8	96,8	96,7	96,2	96,3	96,0	96,1	95,8	96,0	96,5	96,3	96,6

Tabelle 10.1: Anzahl der zur Durchführung der Clusteranalysen beibehaltenen Hauptkomponenten (obere Zeile) und prozentualer Anteil der durch sie repräsentierten Gesamtvarianz der Bodendruckfelder im Zeitraum 1909-1998 für die verschiedenen Kalendermonate.

Bei der eigentlichen Durchführung der Clusteranalysen kam die Methode des „average linkage“ (Gl. 10.2) zur Anwendung. Als Distanzmaß wurde nicht die euklidische Distanz selbst (Gl. 10.1), sondern ihr Quadrat verwendet. Diese Vorgehensweise wurde gewählt, da eine hier durchgeführte Testreihe bestätigt hatte, daß die centroid method (Gl. 10.3) zum sogenannten Schneeballeffekt (engl. snowballing) neigt (*Kalkstein et al.*, 1987). Dabei handelt es sich um einen Effekt, welcher in der Regel einen riesigen, einige kleinere und viele Cluster, die lediglich eine Beobachtung enthalten, zur Folge hat. Er entsteht, weil bei diesem Algorithmus die Größe der einzelnen Cluster u.U. darüber entscheidet, welche Cluster als nächstes miteinander vereint werden. So kann es vorkommen, daß ein Cluster mit einem größeren Cluster vereint wird, obwohl er mehr Ähnlichkeit mit einem kleineren Cluster hat. *Kalkstein et al.* konnten zusätzlich zeigen, daß auch bei der Methode von **Ward** (Gl. 10.4) die Anzahl der Clustermitglieder eine wichtige Rolle spielt, weshalb sie die Anwendung des „average linkage“ empfehlen. Daß hier statt der heute üblichen einfachen euklidischen Distanz deren Quadrat verwendet wurde, ist auf die sich im Rahmen der hier durchgeführten Testreihe ergebenden finalen Clustergrößen zurückzuführen. Wichen die aus beiden Distanzmaßen resultierenden Ergebnisse voneinander ab (nur bei einigen Kalendermonaten der Fall), so führte die Anwendung der einfachen euklidischen Distanz z.T. zu unerwünscht umfangreichen Clustern. Die Resultate, die sich durch die Verwendung der quadratischen euklidischen Distanz ergaben, wurden den Anforderungen der Langfristprognose hingegen deutlich besser gerecht.

10.4 Ergebnisse

Durch die Anwendung der in Abschnitt 10.2 erläuterten Abbruchregel ergaben sich je nach Kalendermonat zwischen 8 und 22 Cluster. Dabei stimmt die Verteilung der einzelnen Beobachtungen, d.h. die Anzahl der Mitglieder der verschiedenen Cluster, gut mit den im Vorfeld der Untersuchung formulierten Erwartungen überein. In der Regel kamen ein bis drei große, mehrere mittlere und kleine sowie einige nur eine Beobachtung umfassende Cluster zustande. Lediglich im Monat Juni sind die Besetzungszahlen der finalen Cluster nicht zufriedenstellend. Hier führen ein 61 Einzeljahre umfassender und 13 weitere, lediglich ein bis fünf Einzeljahre enthaltende Cluster automatisch dazu, daß die Prognose nur in wenigen Fällen deutlich vom Klimamittel abweichen kann. Eine vollständige Aufstellung der Zusammensetzungen aller Cluster ist in Anhang B dieser Arbeit zu finden.

Wie die Tabelle 10.2 zeigt, liegen die RV-Werte der Temperaturvorhersagen im Untersuchungszeitraum trotz der theoretisch guten Ausgangsbasis fast ausnahmslos im

negativen Bereich. Zwar ist die hier ermittelte Vorhersageleistung in keinem Fall statistisch signifikant von Null verschieden, jedoch ist es nach statistischem Ermessen kaum vorstellbar, daß die Clusteranalyse im operationellen Betrieb positive RV-Werte liefern kann. Dieses liegt, neben dem ohnehin stets auftretenden Abfall der Vorhersagequalität am unabhängigen Kollektiv, an der Tatsache, daß der Verlauf der Clusteranalyse immer auch direkt von den künstlich aktuellen Fällen abhängig ist (vergl. Abschnitt 10.3). Es bleibt demzufolge festzuhalten, daß die Anwendung eines einfachen Analogverfahrens mit hoher Wahrscheinlichkeit bessere Ergebnisse liefert (vergl. die Abschnitte 8.2.1 und 8.2.2).

t_0	$t+1$	$t+2$	$t+3$	$t+4$	$t+5$	$t+6$
Januar	-0,03	-0,09	0,01	-0,08	-0,06	-0,08
Februar	-0,05	-0,12	-0,09	-0,03	-0,12	-0,05
März	-0,21	-0,20	-0,13	-0,11	-0,21	-0,24
April	-0,09	-0,08	-0,11	-0,11	0,00	-0,11
Mai	-0,06	-0,10	-0,15	-0,09	-0,08	-0,01
Juni	-0,15	-0,08	-0,04	-0,09	0,01	-0,13
Juli	-0,01	0,00	-0,05	-0,03	-0,14	-0,17
August	-0,14	-0,14	-0,04	-0,12	-0,16	-0,03
September	-0,14	-0,11	0,05	-0,14	-0,03	-0,02
Oktober	-0,07	-0,06	-0,03	-0,05	0,01	-0,14
November	0,02	-0,09	-0,10	-0,11	-0,11	-0,09
Dezember	-0,17	-0,23	-0,13	-0,17	-0,17	-0,16

Tabelle 10.2: Mittels U-Methode abgeschätzte RV-Werte der durch Clusteranalyse erstellten Temperaturprognosen im Zeitraum 1909-1998. Positive Vorhersageleistung ist durch Fettdruck gekennzeichnet.