

Sensorfusion zur Unterdrückung von Störsignalen mittels der Independent Component Analyse

Luis Nachtigall, Andreas Sandmair und Fernando Puente León

Karlsruher Institut für Technologie, Institut für Industrielle Informationstechnik, Hertzstr. 16, D-76187 Karlsruhe

Zusammenfassung Ein wichtiger Anwendungsbereich der Sensorfusion ist die Verbesserung störungsbehafteter Signale. Hierbei werden mehrere Sensorsignale verknüpft, um ihren Nutzanteil zu extrahieren. Im vorliegenden Beitrag wird ein rein statistischer Ansatz zur Störsignalunterdrückung vorgestellt. Dieser stützt sich auf die Gewinnung geeigneter Basissignale mittels der Independent Component Analyse, die eine Trennung von Stör- und Nutzanteilen der Signale ermöglicht. Auf Grund der Allgemeinheit der Methode ist die Anwendung des Ansatzes in verschiedenen Bereichen der Signalverarbeitung möglich. Erfolgreiche Ergebnisse werden am Beispiel der automatischen Sichtprüfung und der Sprachsignalverarbeitung gezeigt.

1 Einleitung

Die Independent Component Analyse (ICA) ist ein statistisches Verfahren zur Zerlegung einer Mischung statistisch unabhängiger Zufallsvariablen in unabhängige Komponenten. Für die Zerlegung müssen nur die Sensorsignale bekannt sein. Dieses Verfahren wird häufig zur Lösung des „*Blind Source Separation*“-Problems (BSS) bzw. des Problems der Blinden Quellentrennung verwendet. Unter Nutzung der statistischen Eigenschaften der Originalsignale können unter bestimmten Bedingungen die Signale mit Hilfe der ICA rekonstruiert werden. Das bekannteste Beispiel im Bereich der Quellentrennung ist das sogenannte „Cocktail-Party-Problem“ [1].

Eine weitere Anwendung der ICA ist die Merkmalsextraktion aus Signalen, wie z. B. Bildern [2]. Ziel ist in diesem Fall, aus beobachteten

Daten Basisfunktionen zu gewinnen, mit denen sich beliebige Signale beschreiben lassen. Jede Basisfunktion oder Merkmal weist bestimmte Eigenschaften auf, die genutzt werden können, um z. B. ein Signal in Nutz- und Störanteile aufzutrennen. Mit diesem Verfahren werden u. a. Defekte in Textilien bei der automatischen Sichtprüfung [3] erkannt.

Im vorliegenden Beitrag wird eine Methode zur Unterdrückung des Hintergrundsignals dargestellt, die auf der Fusion mehrerer Sensorsignale mittels der ICA beruht. Im Folgenden werden als Erstes die ICA und notwendige Erweiterungen vorgestellt. Anschließend wird der Ansatz zur Störungsunterdrückung erläutert und dessen Anwendbarkeit exemplarisch an zwei verschiedenen Beispielen gezeigt: der Defekterkennung auf texturierten Oberflächen und der Störsignalunterdrückung bei Sprachsignalen.

2 Independent Component Analyse im Überblick

Im Allgemeinen kann die ICA als eine Methode zur Zerlegung eines oder mehrerer multivariater Signale in statistisch unabhängige Komponenten betrachtet werden. Als Basis dafür wird ein stochastisches, generatives Modell herangezogen.

2.1 ICA-Modell

Folgendes generative Modell sagt aus, dass m beobachtete Zufallsvariablen als eine Linearkombination von n statistisch unabhängigen stochastischen Komponenten ausgedrückt werden können:

$$\mathbf{x} = \mathbf{A} \cdot \mathbf{s} = \sum_{i=1}^n \mathbf{a}_i \cdot s_i, \quad (13.1)$$

wobei \mathbf{x} den beobachteten Vektor ($m \times 1$), \mathbf{A} die Mischmatrix ($m \times n$) und \mathbf{s} den Vektor ($n \times 1$) der unabhängigen Komponenten darstellt. Des Weiteren werden mit \mathbf{a}_i die Basisvektoren ($m \times 1$) und mit s_i die unabhängigen Komponenten ($s_i \in \mathbb{R}$) bezeichnet.

Die ICA wird verwendet, um die unabhängigen Komponenten s_i eines Vektors \mathbf{x} zu finden:

$$\mathbf{s} = \mathbf{W} \cdot \mathbf{x}. \quad (13.2)$$

Für den Fall, dass $m = n$ ist, gilt $\mathbf{W} = \mathbf{A}^{-1}$. Hierzu ist es wichtig zu bemerken, dass die Mischmatrix \mathbf{A} nicht a priori bekannt ist. So müssen sowohl \mathbf{A} bzw. \mathbf{W} als auch die unabhängigen Komponenten s_i allein aus einer Menge beobachteter Daten geschätzt werden.

Für die Trennung der Signale werden statistische Eigenschaften und die statistische Unabhängigkeit der Originalsignale verwendet. Mit Hilfe des zentralen Grenzwertsatzes (unter bestimmten Bedingungen konvergiert die Summe unabhängiger Zufallsvariablen gegen eine Gaußverteilung) kann somit ein Verfahren für die Bestimmung der unabhängigen Komponenten definiert werden. Unter der Annahme, dass keines der Originalsignale gaußverteilt ist, können die Komponenten rekonstruiert werden, indem durch die Rekonstruktion die Abweichung der einzelnen Wahrscheinlichkeitsverteilungen von der Normalverteilung maximiert wird [1].

Ein Maß für die Abweichung von einer Normalverteilung ist die Kurtosis:

$$\text{kurt}(X) = \frac{\mu_4\{X\}}{\sigma^4\{X\}}, \quad (13.3)$$

wobei $\mu_4\{X\}$ das vierte zentrale Moment und $\sigma\{X\}$ die Standardabweichung bezeichnet. Durch Minimierung bzw. Maximierung der Kurtosis können die unabhängigen Komponenten gefunden werden.

2.2 Merkmalsextraktion

Die Berechnung einer unabhängigen Komponente s_i erfolgt als Innenprodukt zwischen einem Zeilenvektor \mathbf{w}_i^T der Matrix \mathbf{W} und einem beobachteten Vektor \mathbf{x} :

$$s_i = \langle \mathbf{w}_i, \mathbf{x} \rangle = \sum_{k=1}^m w_i^{(k)} \cdot x^{(k)}, \quad (13.4)$$

wobei $w_i^{(k)}$ und $x^{(k)}$ die k -te Komponente der Vektoren \mathbf{w}_i bzw. \mathbf{x} ist.

Üblicherweise wird \mathbf{w}_i als Merkmalsdetektor bezeichnet. In diesem Sinne kann s_i als ein Merkmal von \mathbf{x} verstanden werden. Jedoch ist in der Literatur das Konzept der Merkmale nicht eindeutig definiert: \mathbf{a}_i wird auch als Merkmal bezeichnet, während s_i als die Amplitude des Merkmals im Vektor \mathbf{x} betrachtet wird. In diesem Beitrag wird das Konzept der Merkmale für s_i und \mathbf{a}_i abwechselnd gebraucht.

3 ICA für Signale in Räumen höherer Dimension

Im vorher beschriebenen ICA-Modell sind die Komponenten $x^{(k)}$ des beobachteten Vektors \mathbf{x} skalar (z. B. die Aufnahme eines Signales mit mehreren Sensoren zu einem Zeitpunkt). Das Modell kann erweitert werden, um Beobachtungen bzw. Signale in Räumen höherer Dimension $x(\mathbf{r})$, $\mathbf{r} \in \mathbb{R}^l$ mit $l \geq 1$, zu berücksichtigen:

$$\mathbf{x}(\mathbf{r}) = \begin{pmatrix} x^{(1)}(\mathbf{r}) \\ \vdots \\ x^{(B)}(\mathbf{r}) \end{pmatrix} = \sum_{i=1}^n \begin{pmatrix} a_i^{(1)}(\mathbf{r}) \\ \vdots \\ a_i^{(B)}(\mathbf{r}) \end{pmatrix} s_i = \sum_{i=1}^n \mathbf{a}_i(\mathbf{r}) \cdot s_i, \quad (13.5)$$

wobei B die Anzahl der Signale, $x^{(1, \dots, B)}(\mathbf{r})$ die Komponenten des Signalvektors $\mathbf{x}(\mathbf{r})$ und $a_i^{(1, \dots, B)}(\mathbf{r})$ die Komponenten der Basissignale $\mathbf{a}_i(\mathbf{r})$ bezeichnen.

Als Beispiele für $x(\mathbf{r})$ können zeitliche Folgen akustischer Signale ($\mathbf{r} \in \mathbb{R}$) oder Bilder ($\mathbf{r} \in \mathbb{R}^2$) genannt werden. Die Menge der Basissignale $\mathbf{a}_i(\mathbf{r})$ mit $i = 1, \dots, n$ bildet eine Basis, mit der beliebige Signalvektoren $\mathbf{x}(\mathbf{r})$ generiert werden können.

3.1 Merkmalsextraktion

Die Erweiterung des in Gleichung (13.4) beschriebenen Innenproduktes zur Merkmalsextraktion aus einem Signalvektor $\mathbf{x}(\mathbf{r})$ ergibt:

$$s_i = \langle \mathbf{w}_i(\mathbf{r}), \mathbf{x}(\mathbf{r}) \rangle = \sum_{k=1}^B \int_{\mathbb{R}^l} w_i^{(k)}(\mathbf{r}) \cdot x^{(k)}(\mathbf{r}) \cdot d\mathbf{r}, \quad (13.6)$$

wobei $\mathbf{w}_i(\mathbf{r})$ die zugehörigen Merkmalsdetektoren der Basissignale $\mathbf{a}_i(\mathbf{r})$ sind.

3.2 Praktische Betrachtungen

Die Dimension der Eingangsvektoren bestimmt den Aufwand zur Berechnung der ICA. Für eine praktische Anwendung der ICA soll der Eingangsvektor nicht zu hochdimensional sein. In vielen Fällen wird die Länge des Vektors zu $n = 256$ gewählt. In der Bildverarbeitung ist n von der Wahl des Bildausschnittes abhängig, der für Bildserien (4 Bilder) häufig zu 8×8 Pixeln gewählt wird.

4 Ansatz zur Störsignalunterdrückung

Der Ansatz zur Unterdrückung von Störsignalen basiert auf der Tatsache, dass die Störung und das Nutzsignal unterschiedliche statistische Eigenschaften aufweisen. Im Folgenden werden die einzelnen Schritte zur Störsignalunterdrückung vorgestellt. In Abbildung 13.1 ist der Ansatz nochmals als Blockdiagramm dargestellt.

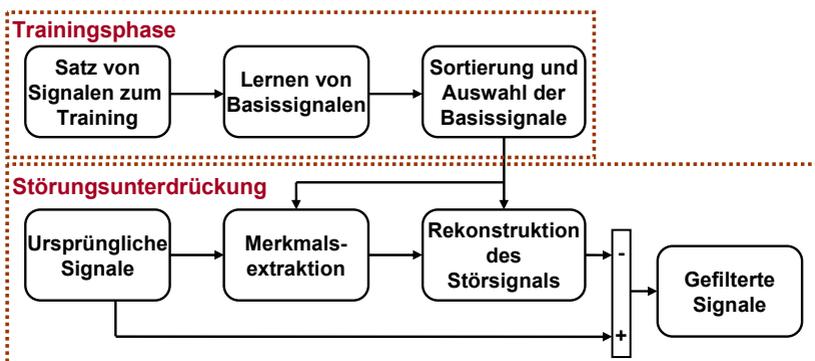


Abbildung 13.1: Konzept der vorgestellten Methode zur Unterdrückung von Störungen.

4.1 Lernen und Sortierung von Basissignalen

Zunächst müssen Basissignale aus beobachteten bzw. gemessenen Signalvektoren gelernt werden. Dafür verwendet man einen Satz aufgenommener Signalvektoren als Eingangsdaten des ICA-Algorithmus, welcher die gesuchten Basissignale $\mathbf{a}_i(\mathbf{r})$ und Merkmalsdetektoren $\mathbf{w}_i(\mathbf{r})$ schätzt.

Jedes gelernte Basissignal oder Merkmal stellt verschiedene Aspekte eines Signalvektors dar. Einige Merkmale enthalten z. B. deutlich mehr Informationen über die Störung als über das Nutzsignal. Eine Zuordnung der Basissignale zu Störung oder Nutzsignal ist somit ein erster Schritt innerhalb der Störsignalunterdrückung. Die Aufteilung der Signale erfolgt mit Hilfe der Kurtosis (siehe Gleichung (13.3)) der geschätzten unabhängigen Komponenten. Unter der Annahme, dass das Nutzsignal seltener auftritt als das Störsignal, haben die Komponenten, die das Nutz-

signal beschreiben, tendenziell eine sehr schmale Verteilung. Die Verteilungen, die das Störsignal beschreiben, sind breiter. Sortiert man die Komponenten nach deren Kurtosis, die ein Maß für die Breite der Verteilung [2] ist, kann eine einfache Auswahl der Stör- und Nutzsignalkomponenten getroffen werden.

4.2 Rekonstruktion und Unterdrückung des Hintergrundsignals

Ein geschätztes Hintergrundsignal $\mathbf{x}_{\text{back}}(\mathbf{r})$ wird aus einer Untermenge der sortierten Basissignale $\{\mathbf{a}_i(\mathbf{r})$ mit $i = 1, \dots, k$ und $k < n\}$ rekonstruiert:

$$\mathbf{x}_{\text{back}}(\mathbf{r}) = \begin{pmatrix} x_{\text{back}}^{(1)}(\mathbf{r}) \\ \vdots \\ x_{\text{back}}^{(B)}(\mathbf{r}) \end{pmatrix} = \sum_{i=1}^k \begin{pmatrix} a_i^{(1)}(\mathbf{r}) \\ \vdots \\ a_i^{(B)}(\mathbf{r}) \end{pmatrix} s_i = \sum_{i=1}^k \mathbf{a}_i(\mathbf{r}) \cdot s_i. \quad (13.7)$$

k wird empirisch bestimmt und liegt normalerweise im Bereich von $0,25n < k < 0,75n$. Da nur Merkmale mit einer breiteren Verteilung zur Generierung von $\mathbf{i}_{\text{back}}(\mathbf{r})$ verwendet werden, wird das Hintergrundsignal durch $\mathbf{x}_{\text{back}}(\mathbf{r})$ gut beschrieben.

Zur Erzeugung eines gefilterten Signals $\mathbf{x}_{\text{filt}}(\mathbf{r})$ – gefiltert im Sinne einer Hintergrundsignalunterdrückung – wird einfach das rekonstruierte Signal $\mathbf{x}_{\text{back}}(\mathbf{r})$ von dem ursprünglichen Signal $\mathbf{x}(\mathbf{r})$ subtrahiert:

$$\mathbf{x}_{\text{filt}}(\mathbf{r}) = \mathbf{x}(\mathbf{r}) - \mathbf{x}_{\text{back}}(\mathbf{r}). \quad (13.8)$$

4.3 Anwendungen

Der vorgestellte Ansatz lässt sich bei verschiedenen Arten von Signalen einsetzen. In den nächsten Abschnitten werden zwei Anwendungen vorgestellt: die Defektdetektion auf lackierten texturierten Oberflächen und die Störsignalunterdrückung bei Sprachsignalen.

5 Defekterkennung auf lackierten Holzoberflächen

Bilder können als Grundlage zur automatischen Sichtprüfung technischer Oberflächen herangezogen werden, z. B. zur Erkennung von Defekten in

Textilien und lackierten Oberflächen [4]. Besonders schwierig zu inspizieren sind die sogenannten „nichtkooperativen Oberflächen“, bei denen Defekte unter bestimmten Beobachtungs- und Beleuchtungsrichtungen unsichtbar werden können [5, 6]. Insbesondere sind Defekte auf Holzoberflächen, die mit durchsichtigen Lacken bearbeitet wurden, schwierig zu erkennen, da die Holztextur einen „störenden“ Hintergrund darstellt.

5.1 Bildserienaufnahme

Um die beschriebenen Probleme zu bewältigen, ist der Einsatz von Bildserien mit variabler Beleuchtung hilfreich. In Abbildung 13.2 wird ein Aufbau zur Bildserienaufnahme schematisch dargestellt. In diesem Aufbau ist die Kamera in der oberen Position fixiert, während die Lichtquelle mit festem Elevationswinkel θ und variablem Azimut φ positioniert werden kann.

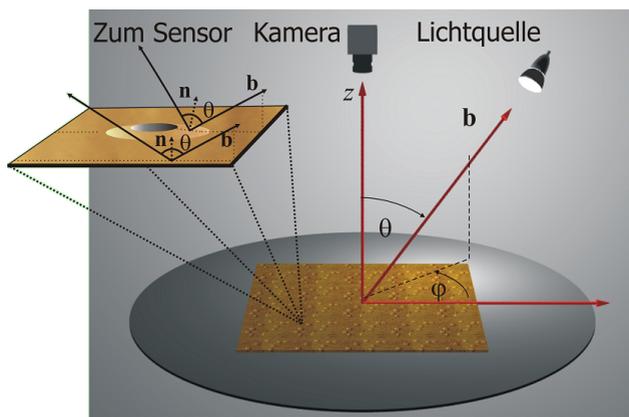


Abbildung 13.2: Schema des Aufbaus zur Aufnahme von Bildserien.

Mit der Betrachtung von Bildserien wird das Problem der automatischen Sichtprüfung komplexer, da jetzt nicht nur ein Einzelbild $i(\mathbf{r})$, sondern sämtliche Bilder aus der Bildserie – d. h. der Bildvektor $\mathbf{i}(\mathbf{r})$ –, welche komplementäre Information über die Szene enthalten, gleichzeitig verarbeitet werden müssen. Der Signalraum wird somit um eine dritte Dimension erweitert (siehe Abbildung 13.3). Der beschriebene ICA-basierte Ansatz wird zur Fusion der Bildserie herangezogen.

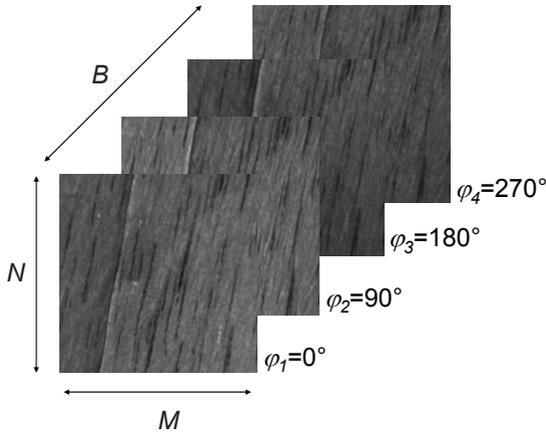


Abbildung 13.3: Grafische Darstellung einer Bildserie (M : Breite, N : Höhe, B : Anzahl der Bilder).

5.2 Defekterkennung

Defekte auf lackierten Oberflächen können anhand der Fusion der Bilder einer Beleuchtungsserie nach dem in Abbildung 13.4 beschriebenen Schema erkannt werden. Eine ausführliche Beschreibung der Methode wird in [7] dargestellt.

5.3 Ergebnisse

Der Bildvektor besteht aus $B = 4$ Einzelbildern mit unterschiedlichen Beleuchtungsrichtungen. Bildausschnitte der Größe 8×8 Pixel wurden als Komponenten $i^{(1,\dots,4)}(x, y)$ des Bildvektors $\mathbf{i}(x, y)$ betrachtet. In Abbildung 13.5 werden die ursprünglichen Bilder $i^{(1,\dots,4)}(x, y)$ (siehe Bilder 13.5(a)–(d)) und die geschätzten Textur- bzw. Hintergrundbilder $i_{\text{back}}^{(1,\dots,4)}(x, y)$ (siehe Bilder 13.5(e)–(h)) gezeigt. Als Eingangsdaten für die ICA-Trainingsphase wurden Bildausschnitte der ursprünglichen Bilder verwendet.

Die geprüfte Oberfläche enthält zwei Risse, die im oberen und im unteren Bereich der ursprünglichen Bilder zu sehen sind. Diese sind aber in den rekonstruierten Texturbildern beinahe nicht zu erkennen.

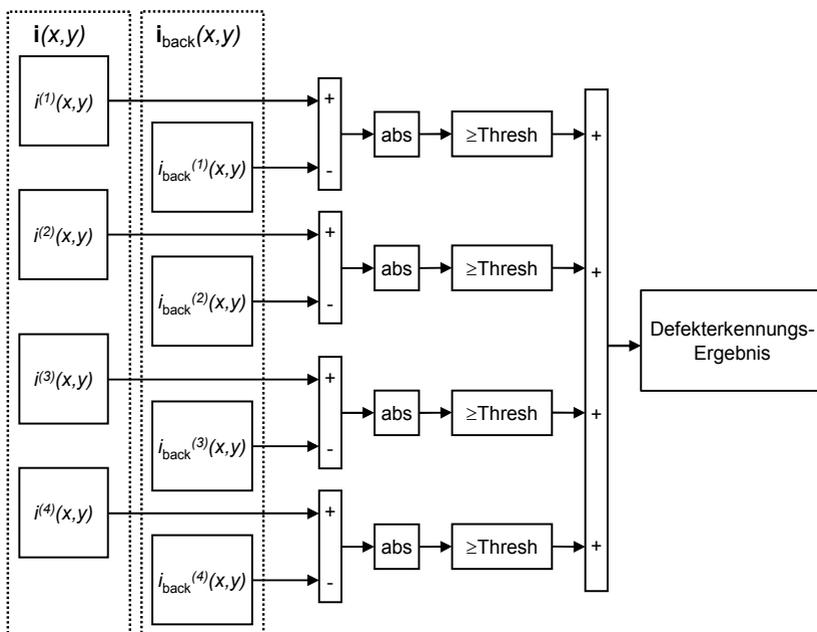


Abbildung 13.4: Schema des Segmentierungsverfahrens.

Nach Anwendung des Segmentierungsverfahrens erhält man das Ergebnis in Abbildung 13.6. Beide Risse wurden gut erkannt, wie es in Abbildung 13.6 zu beobachten ist. Zusätzlich erscheinen spärlich verteilt einige hellblaue Punkte. Diese ergeben sich aus kleineren lokalen Unregelmäßigkeiten der Oberfläche. Da sie nur spärlich auftreten, werden sie durch die Methode auch als Defekte erkannt.

6 Störsignalunterdrückung bei Sprachsignalen

Aufgrund der guten Ergebnisse bei der Schätzung des Hintergrundsignals im Bereich der zweidimensionalen Signalverarbeitung wird die Methode zur Unterdrückung von Störsignalen auch bei Sprachsignalen geprüft. In Bereich der Sprachsignalverarbeitung soll aus einer additiven Überlagerung von Nutzsignal $x(t)$ und Störsignal $r_D(t)$ der relevante Anteil

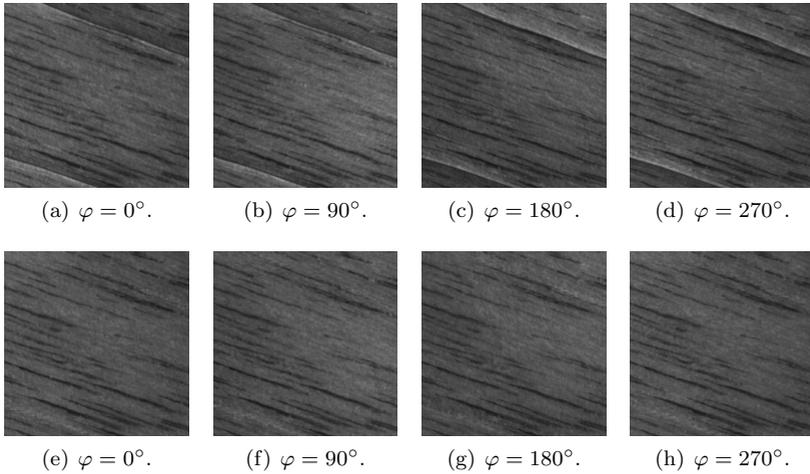


Abbildung 13.5: Bildserien einer geprüften Oberfläche. (a)–(d): Ursprüngliche Bilder. (e)–(h): Rekonstruierte Texturbilder.

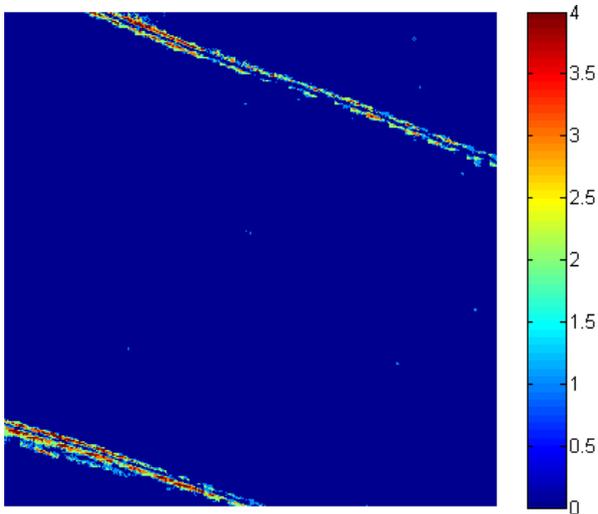


Abbildung 13.6: Prüfergebnis einer defektbehafteten Holzoberfläche. Die Farbskala deutet die Gewissheit der Defekte an (blau $\hat{=}$ kein Defekt; rot $\hat{=}$ Defekt).

herausgefiltert werden. Vor der Evaluation der Methode müssen jedoch die Bedingungen für die Simulation der Sensorsignale erläutert werden. Im Folgenden werden für die Ausbreitung der Schallsignale Freifeldbedingungen angenommen. Die einzelnen Signale kommen verzögert am Sensor an. Für das i -te Sensorsignal $s_i(t)$ gilt somit

$$s_i(t) = x(t - \Delta_{x,i}) + r_D(t - \Delta_{r,i}). \quad (13.9)$$

Die räumliche Trennung der Quellen führt zu unterschiedlichen Verzögerungen Δ . Bei der Aufnahme der Signale mit mehreren, räumlich getrennten Sensoren ergeben sich definierte Laufzeitunterschiede für die einzelnen Quellen. Ein Verfahren, derartige Signale zu trennen, stellen beispielsweise Methoden zur Quellentrennung auf Basis der ICA dar [8]. Die Trennung der Signale ist für beliebige Signale möglich und erfolgt im Frequenzbereich. Im Gegensatz dazu wollen wir ein Verfahren zur reinen Störsignalunterdrückung im Zeitbereich präsentieren und die Ergebnisse gegenüberstellen.

Für die folgenden Betrachtungen werden zwei Sensoren verwendet. Der Störanteil ergibt sich zu $r_D(t) = n r(t)$, um ein beliebiges Verhältnis von Nutz- und Störsignal erzeugen zu können. Das ursprüngliche Störsignal $r(t)$ und das Nutzsinal $x(t)$ sind in Abbildung 13.7 dargestellt.

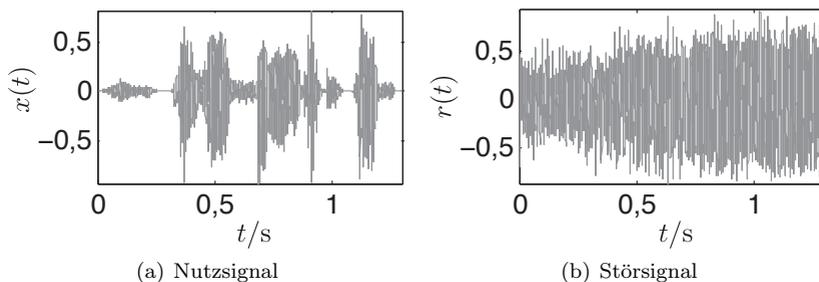


Abbildung 13.7: Das Nutzsinal $x(t)$ und das Störsignal $r(t)$ werden zur Erzeugung der Sensorsignale verwendet.

Analog zu den Bildsignalen ist die Störung über alle Zeiten sehr dominant. Aus diesem Grund können mit Hilfe unseres Verfahrens Basisfunktionen gelernt werden, die den Störanteil des Signals gut beschreiben.

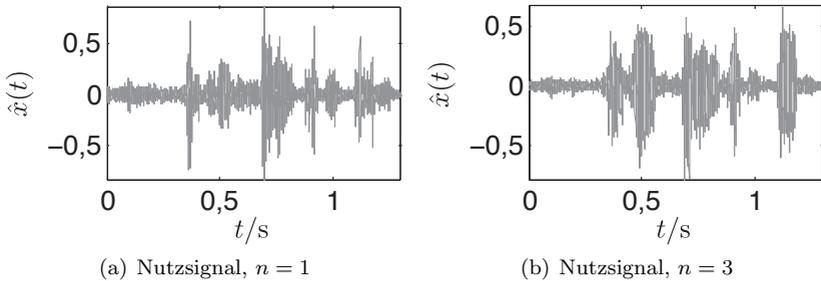


Abbildung 13.8: Ergebnisse der Unterdrückung des Störsignals für unterschiedliche Verstärkungen des Störsignals.

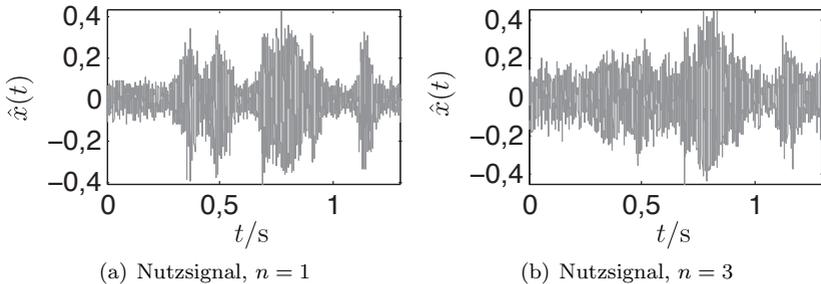


Abbildung 13.9: Ergebnisse der Unterdrückung des Störsignals für unterschiedliche Verstärkungen des Störsignals unter Verwendung eines Verfahrens zur Quellentrennung.

Die Trainingssignale für die Bestimmung der Basisfunktionen und die Signale, bei denen die Störung unterdrückt werden soll, sind identisch.

Nach Anwendung unseres Verfahrens auf zwei unterschiedliche Überlagerungen von Nutz- und Störsignal konnten die in Abbildung 13.8 dargestellten Signale rekonstruiert werden. Die Rekonstruktion liefert bessere Ergebnisse bei einem höheren Störanteil in den Mischsignalen. Die Begründung liegt in der Art der Störungsschätzung. Ist das Störsignal dominanter, werden hauptsächlich Basisvektoren berechnet, welche das Störsignal beschreiben. Bei der Rekonstruktion wird die Störung somit deutlich genauer geschätzt und das Rekonstruktionsergebnis ist besser.

Für einen Vergleich wurde zudem ein Verfahren zur Quellentrennung auf der Basis von [8] implementiert. Die Ergebnisse für die Rekonstruktion des Nutzsignals sind in Abbildung 13.9 dargestellt. Für $n = 1$ ist der übrige Störanteil höher als bei unserem Verfahren, die Einhüllende wird jedoch deutlich genauer geschätzt. Der Vorteil des vorgestellten Verfahrens zeigt sich vor allem bei höherem Störanteil. Aufgrund der dominierenden Störung kann keine effiziente Quellentrennung durchgeführt werden (Abbildung 13.9(b)). Durch die Schätzung des Störanteils erfolgt eine deutlich genauere Schätzung des Nutzsignals, wie in Abbildung 13.8(b) gezeigt wird.

7 Zusammenfassung

Eine Methode zur Unterdrückung von Hintergrundsignalen wurde vorgestellt. Diese basiert auf der Fusion von Sensorsignalen, die jeweils Überlagerungen von Nutzsignalen und Störungen beinhalten. Diese Störung kann entfernt werden. Mittels der ICA werden Basissignale erzeugt, anhand eines statistischen Kriteriums sortiert und anteilig zur Rekonstruktion verwendet. Wird die Untermenge zur Rekonstruktion der Signale geschickt gewählt, kann das Hintergrundsignal nahezu fehlerfrei rekonstruiert werden. Dieses synthetisierte Signal wird zur Unterdrückung der Störung verwendet. Exemplarisch wurde der Ansatz zur Defekterkennung auf lackierten Oberflächen und zur Unterdrückung stationärer Störungen bei Sprachsignalen angewendet. In beiden Fällen konnte die Störung deutlich unterdrückt werden.

Danksagung

Diese Arbeit wurde teilweise von der Spanischen Regierung im Rahmen des Projektes VAMAD finanziert.

Literatur

1. A. Hyvärinen und E. Oja, „Independent component analysis: algorithms and applications“, *Neural Netw.*, Vol. 13, Nr. 4-5, S. 411–430, 2000.
2. A. Hyvärinen, J. Hurri und P. Hoyer, *Natural Image Statistics: A Probabilistic Approach to Early Computational Vision*. Springer, 2009.

3. O. Sezer, A. Ertuzun und A. Ercil, „Independent component analysis for texture defect detection“, *Pattern Recognition Image Anal.*, Vol. 14, S. 303–307, 2004.
4. X. Xie, „A review of recent advances in surface defect detection using texture analysis techniques“, *Electronic Letters on Computer Vision and Image Analysis*, Vol. 7, Nr. 3, S. 1–22, 2008.
5. A. Pérez Grassi und F. Puente León, „Invariant features from series of images to detect and classify varnish defects“, in *Reports on Distributed Measurement Systems*, F. Puente León, Hrsg. Aachen: Shaker Verlag, 2008, S. 53–67.
6. C. Lindner und F. Puente León, „Segmentierung strukturierter Oberflächen mittels variabler Beleuchtung“, *Technisches Messen*, Vol. 73, Nr. 4, S. 200–207, 2006.
7. L. Nachtigall, A. Pérez Grassi und F. Puente León, „Independent component analysis of image series for defect detection in textured surfaces“, in *Reports on Industrial Information Technology*, F. Puente León und K. Dostert, Hrsg. Karlsruhe: KIT Scientific Publishing, 2010, S. 53–67.
8. P. Smaragdís *et al.*, „Blind separation of convolved mixtures in the frequency domain“, *Neurocomputing*, Vol. 22, Nr. 1, S. 21–34, 1998.