

Artefakterkennung und Signalrekonstruktion im Pupillogramm

L. Herrmann, R. Schüler

18. Februar 2000

Artefactrejection and signal-reconstruction in the pupillogramm

Zusammenfassung

Ganz ähnlich wie verschiedene Wach- und Schlafphasen das EEG verändern, finden wir auch in der Zeitreihe des Pupillendurchmessers Segmente, die über das Vigilanzniveau der Versuchsperson Auskunft geben [4].

Experimentelle Anordnungen für die Messung des Pupillogramms lassen sich in der Literatur zahlreich finden. Interessante Verfahren der Signalverarbeitung sind in [7] und [5] dargestellt. Zur Zeit werden pupillografische Messungen gern zur Erfolgskontrolle nach der Schlaftherapie verwendet.

Ein bisher ungelöstes Problem ist die optimale Behandlung von Artefakten, die durch Lidschlüsse im Pupillogramm entstehen.

Im folgenden Artikel wird ein neues Verfahren zur Artefakterkennung und Signalrekonstruktion vorgestellt, das mit neuronalen Klassifikatoren, die auf dem backpropagation- Verfahren [9] beruhen, gestörte Abschnitte im Biosignal erkennt und die Fehlstellen durch ein einfaches AR- Modell mit Schätzwerten auffüllt.

Die Wirkungsweise der Signalschätzung wird zunächst an einem Testsignal und danach am gestörten Pupillogramm untersucht.

Schlüsselwörter : Artefaktbehandlung, Neuronales Netz, AR-Modell, Pupillogramm

Abstract

Similar to the different wake and sleep stages in the eeg there exist different patterns in pupil dynamics in dependence on the vigilance of

the tested person. Some interesting remarks according to registration and processing of pupil signals can be found in [7, 5].

An up to now unsolved problem is an optimized procedure for handling of artifacts evolving through eye blinks.

The article proposes a procedure for artifact recognition by backpropagation networks, and a following signal reconstruction by an ar-like model. The signal estimation is first demonstrated by test signal and thereafter by a corrupted pupillogramm.

Keywords : artifact processing, neural network, ar-model, pupillogramm

Inhaltsverzeichnis

1	Detektion der Lidschlußartefakte	4
2	Signalrekonstruktion mit AR- Modell	6
3	Zusammenfassung und Ausblick	10
A	Verzeichnis der verwendeten Abkürzungen	11

1 Detektion der Lidschlußartefakte

Lidschlüsse im Pupillogramm (Bild 1) lassen sich mit einfachen Schwellwertverfahren [5] finden. Bei aller Einfachheit dieser Methode bereitet die Einstellung des Triggers einige Schwierigkeiten, da so gezielt diagnostische Parameter beeinflusst werden können. Künstliche neuronale Netze (KNN) eignen

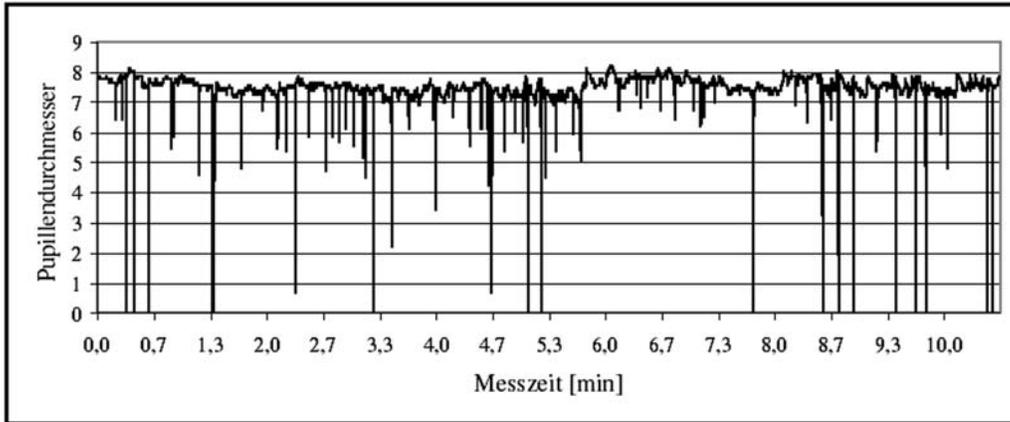


Abbildung 1: Pupillogramm

sich gut für die Segmentierung von Biosignalen [6]. Für die Verwendung von KNN zur Signaldetektion sprechen folgende Punkte:

1. einfach belehrbares Ein- Ausgabe- Verhalten
2. Fähigkeit zum Generalisieren
3. zahlreiche, gut untersuchte Paradigmen und dazugehörige numerische Bibliotheken verfügbar

Das verwendete Neuron und die Topologie des verwendeten multi-layer-perceptron sind in Bild 2 und 3 dargestellt.

Für die Belehrung des KNN wurde das backpropagation- Verfahren [9], [8] verwendet. Die Belehrungsvorschrift ist aus Gl. 1 ersichtlich.

$$\Delta w_k(i) = -\gamma \frac{\partial E}{\partial w_k} + \alpha \Delta w_k(i-1) \quad (1)$$

Für die Belehrung notwendigen Lernmuster werden interaktiv mit einem Signaleditor aus dem gestörten Pupillogramm ausgewählt. Nach der Belehrung erkennt das Netz die Lidschlüsse (Bild 4) mit einer Erkennungsrate von 95% ohne Nachbelehrung.

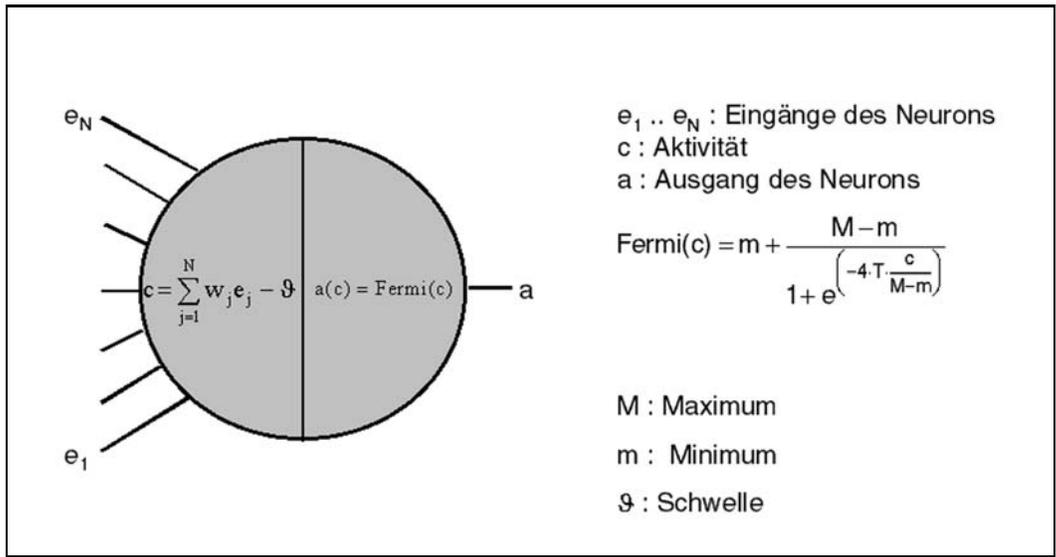


Abbildung 2: Schematischer Neuronenaufbau

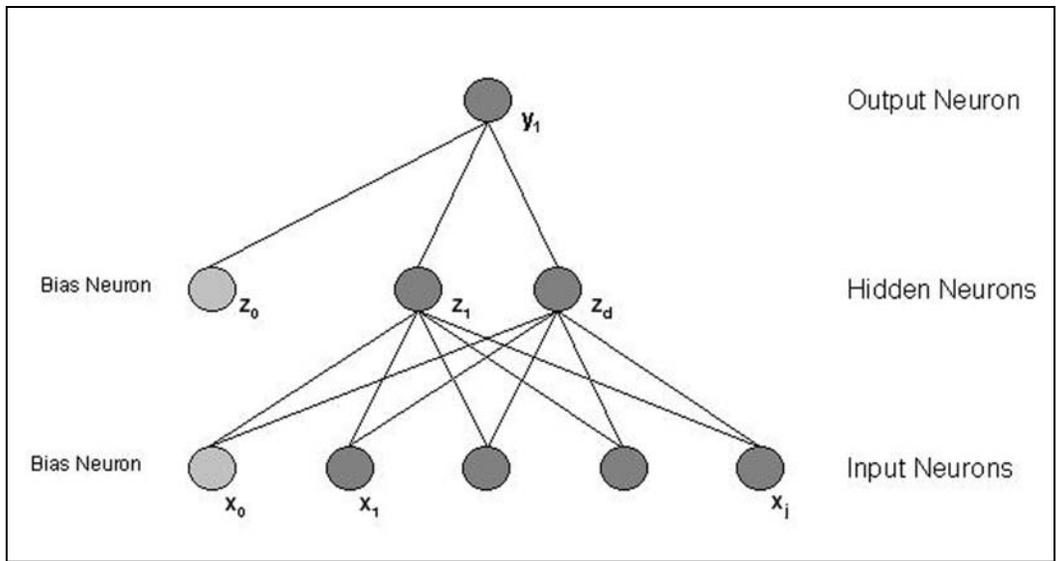


Abbildung 3: Topologie des KNN

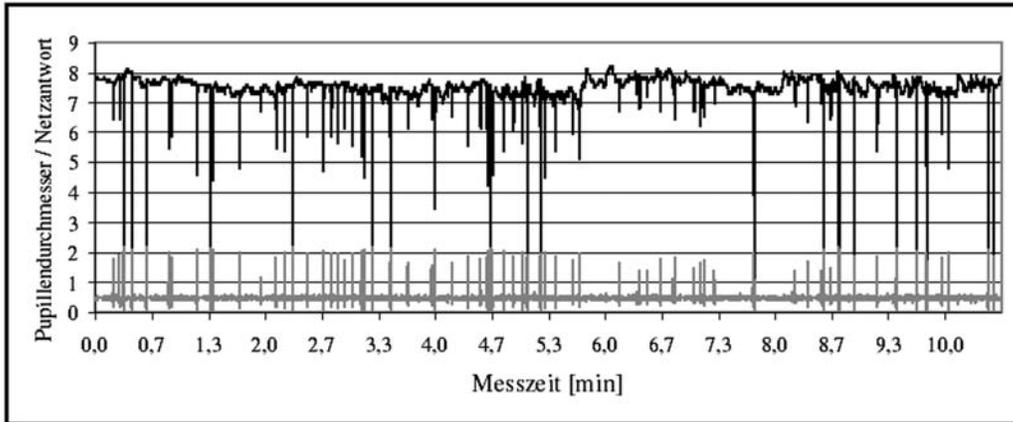


Abbildung 4: Pupillogramm mit Netzantwort

Optimierte Lernstichproben können dieses Ergebnis noch verbessern. Einen Eindruck vom Lernverhalten und der Artefaktdetektion gibt das Demo unter [?].

2 Signalrekonstruktion mit AR- Modell

Für die Schätzung unbekannter Zeitreihenelemente bieten sich autoregressive Modelle an [2]. Mit dem AR- Modell (Gl. 2) lassen sich unbekannte Abtastwerte x_n aus der Historie des Signals $x_{n-p} \dots x_{n-1}$ und dem Parametervektor a schätzen.

$$x_n = \sum_{k=1}^p a_k x_{n-k} + e_n \quad (2)$$

Soll mehr als ein unbekannter Wert geschätzt werden, so kann, Stationarität vorausgesetzt, Gl. 2 auch für weitere x_i verwendet werden (Gl. 3 und Gl. 4).

$$x_{n+1} = \sum_{k=1}^p a_k x_{n-k+1} + e_{n+1} \quad (3)$$

$$x_{n+2} = \sum_{k=1}^p a_k x_{n-k+2} + e_{n+2} \quad (4)$$

In Matrixform ergibt sich Gl. 5

$$x = Xa + e \quad (5)$$

Ähnlich wie für Audiosignale in der Arbeit von Vaseghi [10] wird \hat{a} aus dem ungestörten Signal vor und/oder nach dem Artefakt geschätzt (Gl. 6).

$$\hat{a} = [X^T X]^{-1} X^T x \quad (6)$$

Ein Problem stellt die Bestimmung der Ordnung des AR-Modells dar. In [3] wird ein AR-Modell mit $p=30$ für die Entstörung alter Grammophonaufnahmen verwendet. Die minimal notwendige Ordnung kann aus der Analyse der Residuen des AR-Modells in Abhängigkeit von der Ordnung p gefunden werden [1]. Werden die Quadrate der Residuen über die Ordnung p abgetragen, dann ist gut die minimal notwendige Ordnung zu erkennen, das heißt, längere Vektoren a verbessern die Schätzung für x_n nur noch unwesentlich [2]. Sollen mehr als ein unbekanntes x_i geschätzt werden, so bietet sich theoretisch der Ansatz nach Gl. 7 an.

$$x_{n+q} = b_0 x_n + b_1 x_{n+1} + \dots + b_{q-1} x_{n+q-1} + a_1 x_{n-1} + a_2 x_{n-2} + \dots + a_p x_{n-p} + e_n \quad (7)$$

Dieses ARMA-Modell nutzt die Ergebnisse der Vorhersagen für $x_n \dots x_{n+q-1}$ für die Schätzung des Wertes x_{n+q} [2],[8]. Die Parametrisierung bereitet jedoch erhebliche Schwierigkeiten.

Zunächst soll die Wirkungsweise des Rekonstruktionsverfahrens für ein Testsignal $s(t)$ (Gl. 8) bzw. die entsprechende Zeitreihe (Gl. 9)(Bild 5) untersucht werden.

$$s(t) = [\hat{x}_1 \sin(2\Pi f_1 t + \phi_1) + \hat{x}_2 \sin(2\Pi f_2 t + \phi_2)] e^{-kt} \quad (8)$$

$$s(i) = \left[\hat{x}_1 \sin\left(2\Pi f_1 \frac{i}{i_{ENDE}} + \phi_1\right) + \hat{x}_2 \sin\left(2\Pi f_2 \frac{i}{i_{ENDE}} + \phi_2\right) \right] e^{-ki} \quad (9)$$

Nach Einfügen eines Artefaktes (Bild 6) wird a bestimmt. Die rekonstruierten Signaleile (Bild 7) und der geringe Schätzfehler (Bild 8) zeigen, daß auf das in [10] diskutierte iterierte Verfahren hier verzichtet werden kann. Die gefundenen Restfehler mit einem maximalen Betrag von 10^{-4} liegen für ein 12bit-quantisiertes Meßsignal unterhalb der digitalen Auflösung und haben damit keine praktische Bedeutung.

In Bild 9 ist ein fertig verarbeitetes Pupillogramm dargestellt. Aus den ersten 3 Sekunden des Signals wurden die Lernmuster ausgewählt und damit das KNN trainiert. Anschließend wurden die gefundenen Artefakt-Stellen mit einem AR-Modell 6. Ordnung rekonstruiert.

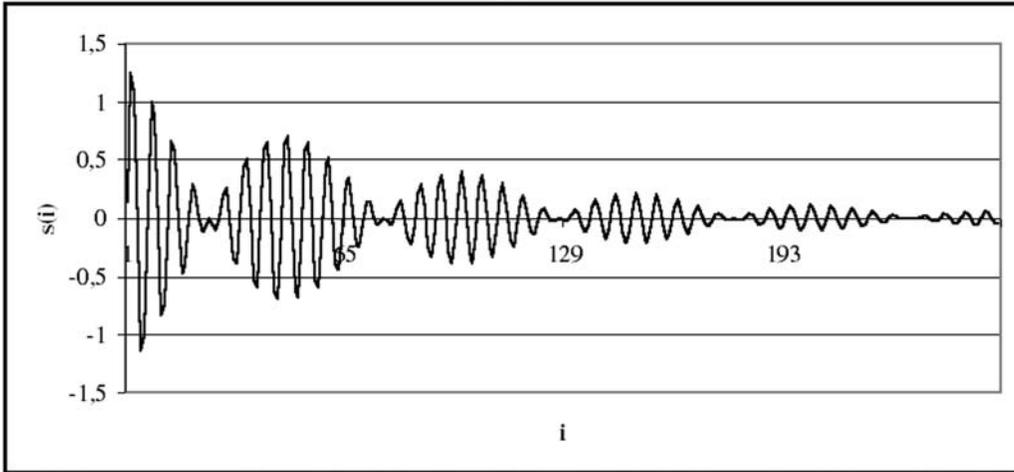


Abbildung 5: Testsignal

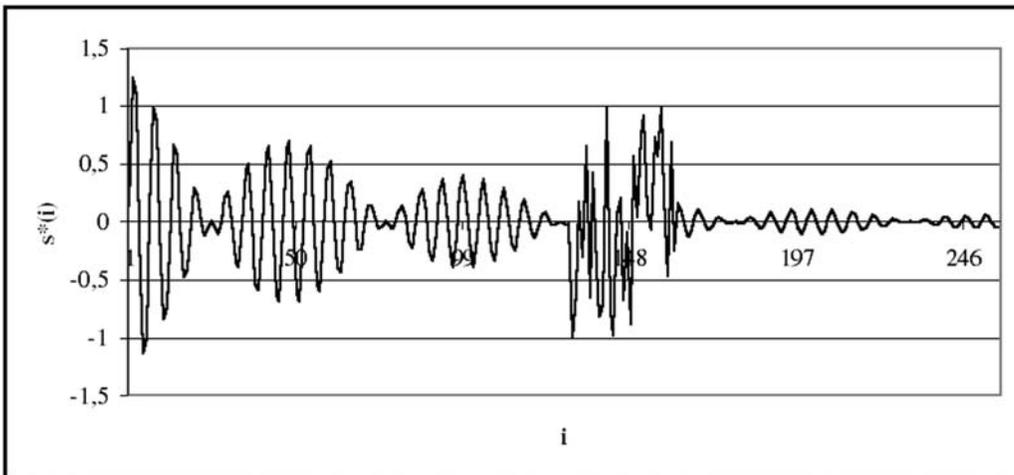


Abbildung 6: Testsignal mit Störung

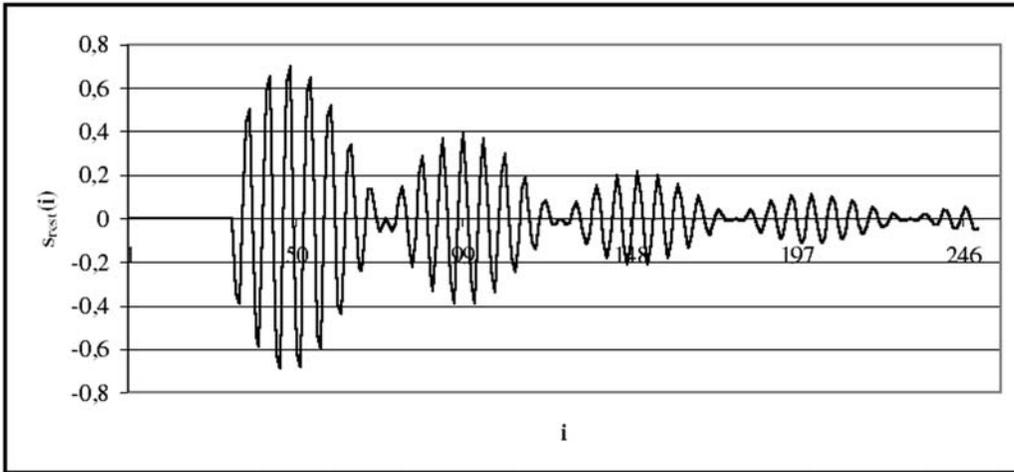


Abbildung 7: Rekonstruiertes Testsignal

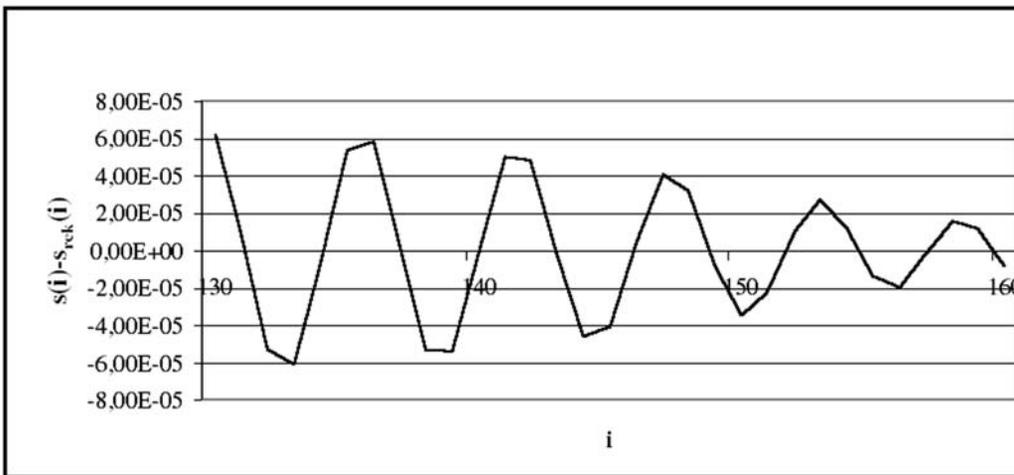


Abbildung 8: Schätzfehler

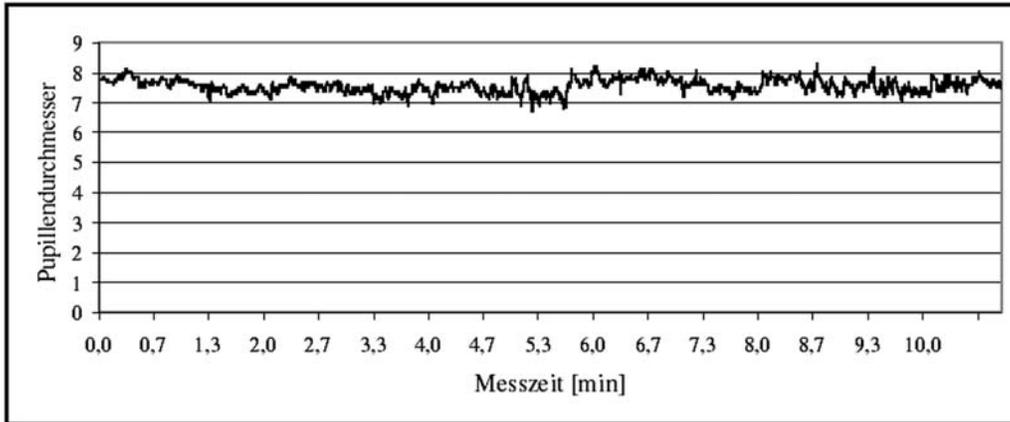


Abbildung 9: Verarbeitetes Pupillogramm

3 Zusammenfassung und Ausblick

Unsere Untersuchung hat ergeben, daß sich autoregressive Modelle gut zur Schätzung von fehlenden Signalteilen im Pupillogramm eignen. Versuche mit künstlichen und Meßsignalen haben gezeigt, daß die Güte der Rekonstruktion mit einiger Empirie (Wahl der Lernmuster, Struktur, Lernrate und Momentum im KNN, Wahl der Signalhistorie für die Rekonstruktion) behaftet ist.

Nichtsdestotrotz weisen die gewählten Algorithmen eine erhebliche Robustheit auf, sodaß auch suboptimale Parametersätze zu guten Ergebnissen führen. In weiteren Arbeiten sollen analytische Ansätze für die Parameterfindung und die Eignung des Ansatzes für andere Biosignale untersucht werden.

A Verzeichnis der verwendeten Abkürzungen

w_k - Gewicht der k-ten Verbindung

E - Quadratischer Fehler aller Lernmuster

γ - Lernrate

α - Momentum

x - Signalvektor

a - AR-Parametervektor

b - ARMA-Parametervektor

e - Rauschvektor

X - Signalmatrix

s - Testsignal

Literatur

- [1] Box, G.; G. Jenkins: *Time series analysis, forecasting and control*. Holden-Day, San Francisco, (1970)
- [2] Chatfield, C.: *The analysis of time series*. Chapman and Hall, London, (1991)
- [3] Godsill, S. J.: *The restoration of degraded audio signals*. Dissertation at the University of Cambridge, (1993)
- [4] Lowenstein, O.; R. Feinberg; I. Lowenfeld: *Pupillary movements during acute and chronic fatigue. A new test for the objective evaluation of tiredness*. Investigative Ophthalmology 2, pp. 138-157, (1963)
- [5] Lüdke, H. et al.: *Mathematical procedures in data recording and processing of pupillary fatigue waves*. Vision Research 38, pp. 2889-2896, (1998)
- [6] Herrmann, L.; U. Rienäcker: *Verbesserung von Lernverhalten und Diskriminationsleistung neuronaler Netze bei der Mustererkennung in Biosignalen*. Biomed.Technik 37, S.69-72, (1992)
- [7] Nguyen,A. H.; L. W. Stark: *Model control of image processing: pupilometry* Computerized Medical Image and Graphics, Vol. 17, No. 1, pp 21-33, (1993)
- [8] Rojas, R.: *Neural networks*. Springer, Berlin Heidelberg, (1996)
- [9] Rumelhart, D.; J. McClelland: *Parallel distributed processing*. MIT Press, Cambridge, (1986)
- [10] Vaseghi, S. V.: *Algorithms for restoration of degraded audio signals*. Dissertation at the University of Cambridge, (1988)