

TEKNILLINEN KORKEAKOULU

Teknillisen fysiikan  
koulutusohjelma

ERIKOISTYÖ

Tfy-61.195 Informaatiotekniikka

30. elokuuta 2000

Polygrafian mittaaminen ja visualisointi itseorganisoituvalla  
kartalla

Jussi Nurminen

48476J

# 1 Johdanto

Ihmisen aivotoiminta, lihasjännitys ja silmänliikkeiden määrä vaihtelevat vireystilan mukaan. Kaikkia näitä muuttujia voidaan seurata ihon pinnalle kiinnitettyjen elektrodien avulla. Työn tarkoituksena oli tutkia eri vireystilojen ja toimintojen erottelua tällaisen polygrafianauhoituksen avulla. Mitatuista elektroencefalografia(EEG), elektro-okulografia(EOG)-, ja elektromyografia(EMG)-signaaleista laskettiin sopivia piirteitä, ja saadun piirrevektorin ja sen aikakehityksen visualisointiin käytettiin itseorganisoituvaa karttaa.

Tavoitteena oli saada ainakin uni- ja valvovaiheet erottumaan toisistaan, ja lisäksi tutkia missä määrin menetelmä pystyy eri univaiheiden, valvetoimintojen yms. erotteluun.


## 2 Polygrafian mittaus ja signaalit

Ensimmäinen vaihe oli vuorokauden mittainen polygrafianauhoitus, jossa työn tekijä toimi koehenkilönä. Nauhoitus tehtiin kotiloissa normaalia vuorokausirytmää noudattaen, ja siihen sisältyi muutamia etukäteen sovittuja toimintoja, kuten TV:n katselua, kirjan lukemista, ja liikuntaa. Koehenkilö piti päiväkirjaa suorittamistaan toiminnoista.

### 2.1 EOG

Silmän varausjakauma muistuttaa sähköistä dipolia, mikä mahdollistaa silmänliikkeiden tutkimisen silmän lähelle asetettujen elektrodien avulla. Potentiaaleja indusoivat sekä katseen siirtämiseen liittyvät silmänliikkeet että silmänräpytyksiin liittyvät silmän liikkaukset. Erilaiset liikkeet voidaan tunnistaa signaalista aaltomuotojen perusteella.

Tässä työssä päätettiin tyytyä silmänräpytyksien tunnistamiseen ja jättää muut silmänliikkeet huomiotta. Räpytykset (blinks, blinkit) vähenevät keskittymistä vaativien visuaalisten toimintojen (esim. kirjan lukeminen) aikana ja luonnollisesti loppuvat kokonaan unen aikana. Ne näkyvät EOG-signaalissa suhteellisen korkea-amplitudisina, nopeina (n. 0.2 - 0.3 s) muutoksina. Ks. kuvaa 1.



Kuva 1: Silmänräpytyksiä suodattamattomassa EOG-signaalissa.

Elektrodit sijaitsivat vasemman silmän ympärillä. Näytteenottotaajuus oli 100 Hz.

## 2.2 EMG

EMG:llä seurataan lihasjännityksen aiheuttamia potentiaalivaihteluita. Käytössä oli kaksi kanavaa: bipolaarinen EEG-kanava Fp1–F7, jossa nähdään temporaalisen (pään sivulla) purentalihaksen ja otsalihaksen toiminta, ja yleisesti käytetty submentaalin EMG-kanava, jonka elektrodit tulevat mylohyoidilihaksen (leuan alla) päälle. EMG-signaali on suhteellisen korkeataajuista, joten näytteenottotaajuudeksi valittiin 200 Hz.

## 2.3 EEG

EEG:llä tutkitaan aivotoimintaa päähän kiinnitettyjen elektrodien avulla. Potentiaalit syntyvät monimutkaisella tavalla neuroniryhmien toiminnan seurauksena. Mittauksessa käytettiin kansainvälisen 10–20 -järjestelmän mukaan sijoitettuja elektrodeja. Käytettäväksi EEG-kanavaksi valittiin pääläella sijaitseva Cz–Pz. Näytteenottotaajuus oli 100 Hz.

Tässä työssä haluttiin tarkkailla hidasaaltoaktiiviteettia (kuva 2 jota esiintyy kevyessä (univaihe S2) ja syvässä (vaiheet S3 ja S4) ei-REM-unessa (NREM). Tämän toiminnan taajuusalue on 0.75–4 Hz [4].



Kuva 2: Hidasta EEG-aktiiviteettia unen aikana.

Toinen kiinnostuksen kohde oli alfatoiminta, joka on parhaiten pään takaosissa havaittava, 8–13 Hz:n taajuinen rytmi. Alfarytmi on selkeimmillään rentouttaessa ja silmät suljettuina, ja se häviää uneen siirtymisen ja keskittyneiden valvetoimintojen aikana [4]. Ks. kuvaa 3.



Kuva 3: Alfarytmi rentoutumisen aikana.

### 3 Signaalien käsittely ja piirteiden erottelu

Seuraavaksi saaduista signaaleista laskettiin niiden ominaisuuksia kuvaavia numeerisia piirteitä. EEG-kanavalta laskettiin kaksi piirrettä ja muilta kanavilta yksi kanavaa kohden. Lopuksi piirteistä otettiin keskiarvot minuutin mittaiselta ajanjaksolta. Näin saatiin 5-ulotteinen piirrevektori jokaista nauhoituksen minuuttia kohden. Laskenta tehtiin Matlabia ja C-ohjelmointikieltä käyttäen.

#### 3.1 EOG

Blinkkien tunnistamiseksi signaalista suodatettiin ensin weighted-FIR-median-hybrid (WFMH) -suodattimella hitaat silmänliikkeet pois [1]. WFMH-suodatuksessa kunkin suodatettavan signaalin näytteen  $x[n]$  ympäriltä lasketaan neljä summaa:

$$\begin{aligned} a_f[n] &= \frac{1}{N} \sum_{k=1}^N x[n+k] \\ a_b[n] &= \frac{1}{N} \sum_{k=1}^N x[n-k] \\ r_f[n] &= \frac{1}{N} \sum_{k=1}^N r_k x[n+k] \\ r_b[n] &= \frac{1}{N} \sum_{k=1}^N r_k x[n-k] \end{aligned} \quad (1)$$

missä painotettujen summien painokerroin  $r_k$  saa arvot


$$r_k = \frac{4N - 6k + 2}{N(N-1)}. \quad (2)$$

$N$  on ikkunanleveys näytteinä; tässä käytettiin arvoa 22 kuten viitteessä [1]. Suodatuksen lopputulos on summista (kaavat 1) ja näytteen arvosta  $x[n]$  laskettu mediaani:

$$y[n] = \text{med}(a_f[n], a_b[n], r_f[n], r_b[n], x[n]). \quad (3)$$

Suodatin vaimentaa signaalista vaihteluita, joiden kesto on alle  $N$  näytettä. Kun samplaustajuus on 100 Hz, tämä vastaa 0.22 sekunnin aikajaksoa. Vähentämällä suodatettu signaali alkuperäisestä saadaan ylipäästetty signaali, josta hitaat vaihtelut ovat hävinneet. Kuten kuvasta 4 havaitaan, suodatus saa blinkit erottumaan selkeästi signaalista ja helpottaa niiden automaattista tunnistusta. Tarkempi analyysi WFMH-suodattimien toiminnasta on viitteessä [2].


Suodatuksen jälkeen blinkit tunnistettiin ohjelmallisesti amplitudi- ja kestokriteerin avulla. Ylitettäväksi amplitudiksi valittiin 100 mikrovolttia, ylityksen minimikestoksi 30 millisekuntia ja maksimikestoksi 300 millisekuntia. Lisäksi perättäisten tunnistuksen minimiaikaväli säädettiin 150 millisekuntiin, eli tätä tiheämmin esiintyvät perättäiset piikit jätettiin laskematta. Lopuksi tunnistuksista laskettiin summa jokaisen minuutin osalta.



Kuva 4: Alkuperäinen ja suodatettu EOG-signaali.

### 3.2 EMG

Korkeataajuinen lihasaktiiviteetti eroteltiin matalataajuisista komponenteista (EEG yms.) ylipäästösuodatuksella, johon käytettiin kohdassa 3.1 esiteltyä WFMH-suodatusta. Ikkunanleveydeksi asetettiin 5, jolloin suodatin vaimentaa alle 0.025 sekuntia kestäviä muutoksia (vastaava taajuus yli 40 Hz). Saatu alipäästösuo-datettu signaali vähennettiin alkuperäisestä signaalista. Ks. kuvaa 5.



Kuva 5: Alkuperäinen ja suodatettu EMG-signaali.

Piirteet laskettiin summaamalla suodatetun signaalin itseisarvo minuutin jaksojen yli.

### 3.3 EEG

EEG:tä tutkittiin keskiarvostettujen FFT-tehospektien avulla. Signaalia ikkunoi-tiin 256 pisteen Hamming-ikkunalla ja 128 pisteen limityksellä, ja ikkunoi-dusta signaalista laskettiin 256 pisteen FFT-muunnoksen itseisarvon logaritmi. Tulokseksi saatiin arviot signaalin spektristä 0.3906 Hz:n resoluutiolla, 1.28 se-kunnin välein.

Hidasaaltoaktiiviteettia seurattiin keskiarvoistamalla FFT-muunnoksen itseisarvon logaritmeja 2 Hz:iä lähinnä vastaavan FFT-pisteen ympäriltä. Pisteitä vastaavat taajuudet olivat 1.1719, 1.5625, 1.9531, 2.3438 ja 2.7344 Hz. Alfa-rytmille vastaavat 5 pistettä olivat 8.9844, 9.3750, 9.7656, 10.1562 ja 10.5469 Hz. Kapeiden taajuusalueiden käytön havaittiin kokeiluissa selkeyttävän erotte-lua. Alfarytmin esiintyminen ja taajuusalue vaihtelevat subjektista toiseen; koe-henkilön alfarytmi näytti spektrin tutkimisen perusteella keskittyvän 10 Hz:n

ympäri.

Lopulliset minuuttikohtaiset piirteet saatiin keskiarvoistamalla tehoarvot kunkin minuutin ajalta.

## 4 SOM-algoritmi ja SOM Toolbox

SOM [6] on moniulotteisen datan visualisointiin ja analyysiin sopiva menetelmä. Sillä voidaan esittää laajoja datajoukkoja pienen, useimmiten 2-ulotteisen neuroniverkon avulla. SOM:ien tekemiseen ja visualisointiin käytettiin tässä työssä Matlabille tehtyä SOM Toolboxia [5].

SOM-verkon jokaiseen neuronin liittyy mallivektori, jonka dimensio on sama kuin datavektoreiden. Mallivektorien joukko pyrkii edustamaan alkuperäistä data-avaruutta optimaalisella tavalla, ja jokaiselle alkuperäisen avaruuden vektorille löytyy parhaiten vastaava mallivektori (best matching unit, BMU). Lisäksi neuronit ovat järjestyneet kartalle siten, että läheisillä neuroneilla on samankaltaiset mallivektorit. Tämä on SOM:n oleellinen ero vektorikvantisointialgoritmeihin: kartta on mielekkäästi järjestynyt kuvaus data-avaruudesta.

Organisoinnin alussa mallivektorit alustetaan joko dataa hyväksikäyttäen tai satunnaisesti. Sen jälkeen datasta valitaan yksi kerrallaan satunnaisesti vektori  $\mathbf{x}$ , ja etsitään se mallivektori  $\mathbf{m}_c$  (BMU) joka minimoi näiden välisen etäisyyden:

$$\|\mathbf{x} - \mathbf{m}_c\| = \min_i (\|\mathbf{x} - \mathbf{m}_i\|). \quad (4)$$

Sen jälkeen verkkoa päivitetään askel kerrallaan ( $t$  on diskreetti aika) 'venyttämällä' BMU:ta ja tiettyä osaa sen ympäristöstä kohti input-avaruuden vektoria  $\mathbf{x}$ :

$$\mathbf{m}_i(t+1) = \mathbf{m}_i(t) + \alpha(t)h(d_{ci}, t)[\mathbf{x}(t) - \mathbf{m}_i(t)]. \quad (5)$$

$h(d_{ci}, t)$  on kummankin argumentin suhteen ei-kasvava naapurustofunktio, joka määrää miten laajaan BMU:n ympäristöön input-avaruuden vektori vaikuttaa. Usein käytetään gaussista (kellokäyrän muotoista) naapurustofunktiota.  $d_{ci}$  on BMU:n ja  $\mathbf{m}_i(t)$ :n etäisyys  $\|\mathbf{m}_c - \mathbf{m}_i\|$ .  $\alpha(t)$  on oppimismopeuden määräävä parametri.

Yleinen menettely on opettaa kartta kahdessa vaiheessa: ensin käytetään laajaa naapurustofunktiota ja isoa  $\alpha(t)$ :ta, ja sen jälkeen "hienosäätövaiheessa" pienempiä arvoja. Käytännössä laskentaa voidaan nopeuttaa ns. batch training -algoritmeilla [6].

### 4.0.1 Muuttujien normalisointi

Euklidisten etäisyyksien laskentaan vaikuttavat eniten ne vektorikomponentit, joiden arvoalue on suurin. Datavektorit täytyy siis yleensä normalisoida ennen kartan muodostamista, jotta jokaisella komponentilla olisi järjestäytymiseen yhtä suuri vaikutus. Usein käytetään lineaarista muunnosta, jossa komponentin varianssiksi skaalataan 1 ja keskiarvoksi 0.

$$x_n = (x - \bar{x})/\sigma_x \quad (6)$$

$\bar{x}$  on komponentin  $x$  keskiarvo ja  $\sigma_x$  keskihajonta.

Eksponentiaalisesti jakautuneen komponentin suuret arvot tulevat paremmin edustetuiksi kartalla, kun se skaalataan logaritmisesti. SOM Toolboxin logaritminen skaalaus käyttää kaavaa

$$x_n = \ln(x - \min x + 1), \quad (7)$$

jolloin  $x_n$  saa ei-negatiivisia arvoja.

## 4.1 Mallivektorien klusterointi

Datapisteiden klusterointi tarkoittaa niiden järjestyksestä samankaltaisten vektorien keskenään erilaisiksi ryhmiiksi. Samankaltaisuuden mittana voi olla euklidinen etäisyys tai jokin muu sopiva mitta. SOM:n yhteydessä halutaan usein tietoa mallivektorien klusterointisesta, joka tietysti riippuu alkuperäisen datan rakenteesta. Tässä työssä ajatuksena oli löytää kartan eri alueille fysiologinen tulkinta, joka selkeyttäisi datapisteiden luokittelua ja visualisointia.

Klusterointi tehtiin single linkage -algoritmillä, joka on valmiiksi toteutettu Matlabin Statistics Toolboxin `linkage`-funktiossa. Se on hyvin yksinkertainen. Määritellään klusteri  $D_i$  pistejoukoksi, johon voi kuulua yksi tai useampia pisteitä. Kahden klusterin etäisyys määritellään

$$d(D_r, D_s) = \min_{i,j} \|x_{ri} - x_{sj}\|, \quad x_{ri} \in D_r, \quad x_{sj} \in D_s \quad (8)$$

eli käyttäen lähimpien pisteiden etäisyyttä. Nyt etsitään datasta kaksi lähintä klusteria (alussa jokainen piste on siis oma klusterinsa), muodostetaan näistä uusi klusteri, etsitään uudesta joukosta kaksi lähintä klusteria jne. kunnes lopulta on muodostettu "pääklusteri" johon sisältyvät hierarkisesti kaikki muut klusterit. Näin muodostuu puurakenne, jossa jokainen klusteri (paitsi alkuperäiset pisteet) sisältää kaksi tai useampia aliklustereita. Katkaisemalla puurakenne sopivasta kohtaa saadaan jako haluttuun määrään klustereita.

## 5 Tulokset


### 5.1 Kartan muodostuminen

Piirteiden erottelun tuloksena saatiin 5-ulotteinen vektori jokaista nauhoituksen minuuttia kohden. Komponentit olivat: 1) blinkkitaajuus, 2) temporaalinen EMG-summa, 3) submentaalin EMG-summa, 4) 10 Hz:n EEG-teho ja 5) 2 Hz:n EEG-teho. Datapisteitä (minuutteja) oli 1440, vastaten tasan 24 tuntia.

EMG-summamuuttujat muunnettiin logaritmisella muunnoksella (kaava 7), koska niiden arvot näyttivät eksponentiaalisesti jakautuneilta. Tämän jälkeen muuttujat varianssinormalisoitiin (kaava 6).

Varsinainen opetus tehtiin SOM Toolboxin oletusparametreja käyttäen, eli kartta alustettiin lineaarisesti ja opetettiin kahdessa vaiheessa batch training -algoritmillä. Kartan kooksi säädettiin kokeilujen jälkeen 400 yksikköä.


Kuvassa 6 on esitetty komponenttitasot ja U-matriisi (unified distance matrix). Komponenttitasosta nähdään värikoodattuna vektorikomponentin saama arvo kunkin karttayksikön kohdalla. Esim. temporaalinen EMG-komponentti saa pieniä arvoja kartan alimmassa kolmanneksessa. U-matriisi antaa tietoa vierekkäisten karttayksiköiden etäisyyksistä; pienet arvot viittaavat klustereihin (toisiaan lähellä olevien datapisteiden kasaumiin) ja suuret arvot klusterien rajoihin.



Kuva 6: U-matriisi ja komponenttitasot.



Kuva 7: Kartta jaettu värikoodattuihin klustereihin. Mallivektorien suhteelliset arvot jokaisessa karttayksikössä on esitetty pienillä pylväillä.



Kuva 8: Datan ja mallivektorien PCA-projektio. Kukin datapiste on sen klusterin värinen, johon sen BMU kuuluu. Mallivektorien muodostama verkko on mukautunut datapilven muotoon, ja verkon tiheys vaihtelee datan tiheyden mukaan.

Seuraavaksi kartta jaettiin yhdeksään klusteriin kohdan 4.1 mukaan. Näille löydettiin melko selkeät tulkinnat. Klusterijako ja sen värikoodaus on näytetty kuvassa 7. Osa klustereista erottuu selvästi jo alkuperäisestä datasta. Kuvassa 8 on esitetty alkuperäinen data ja SOM-verkko projisoituna datan kolmen tärkeimmän (suurimmat ominaisarvot omaavan) ominaisvektorin määräämään avaruuteen (PCA-projektio).

## 5.2 Klusterien tulkintaa

Kartan ylemmässä puoliskossa lihasaktiiviteetti ja blinkkitiheys ovat suhteellisen korkeita. Yläosan neljä klusteria (keltainen, vihreä, tummanvihreä ja syaani) käsittävät selvästi valvetoimintoja.

Keltaisessa klusterissa blinkkien määrä on vähäisin ja submentaalin EMG kertoo rentoutumisesta. Tähän klusteriin kuvautuvat rennot valvetoiminnot, etenkin ne joihin liittyy visuaalista toimintaa (esim. TV:n katselu), koska tällaisten aikana silmänräpytysten määrä vähenee.

Vihreässä klusterissa on enemmän EMG-aktiiviteettia ja normaali valveaikainen silmänräpytystiheys. Siihen kuvautuvat sekalaisia ”aktiivisempia” valvetoimintoja sisältävät minuutit (esim. ruoanlaitto, keskustelu, vaatteiden vaihto, lyhyet kävelyt paikasta toiseen). Tällaisia minuuotteja oli luonnollisesti paljon, ja klusteriin kuvautui 25 prosenttia mittausdatasta.


Tummanvihreään klusteriin sijoittuvat voimakkainta EMG-aktiiviteettia sisältävät ajanjaksot, lähinnä ruokailu; pureskeluun liittyvät liikkeet ja lihasjännityksen vaihtelut näkyvät voimakkaasti EMG-kanavilla. Tämän alapuolella oleva syaaninvärinen klusteri edustaa fyysistä aktiiviteettia sisältäviä jaksuja, joita oli datassa vähän (muutama käynti ulkona ja yksi lyhyt kävelyretki). Näiden kahden klusterin erottumiseen vaikuttavat myös EEG-muuttujien arvot, jotka niissä aiheuttavat lähinnä elektrodien liikkumisen aiheuttamista artefakteista.

Kartan keskellä, puolivälin alapuolella oleva purppuranvärinen klusteri erottuu voimakkaasti ympäristöstään, kuten U-matriisista ja PCA-kuvasta nähdään. Sille ominaisia piirteitä ovat 10 hertsin alfarytmi ja lihasten rentoutuminen. Tähän klusteriin kuvautuivat unta edeltävät rentoutumisjaksot ja yksi valvejakso, jossa kuunneltiin musiikkia silmät kiinni.


Vasemman alakulman (sininen) ja oikean alakulman (punainen) klustereissa lihasmuuttujat saavat pieniä arvoja ja blinkkejä ei esiinny ollenkaan. Nämä ovat uniklustereita. Punaisissa klustereissa näkyy selkeää 2 hertsin hidasta aktiiviteettia, ja siihen kuvautuvat kokeilujen perusteella syvät univaiheet S3 ja S4 sekä kevyt vaihe S2. Siniseen klusteriin näyttävät sijoittuvan REM-unijaksot ja kevyt S1-uni; S1:sen kuvautumista ei tarkasti tutkittu. Käytettyjen muuttujien avulla ei ilmeisesti voida erottaa REM- ja S1-unta toisistaan.

Tummanpunaiseen ja tummansiniseen klusteriin liittyy pieni lihasaktiiviteetin lisääntyminen, ja niihin kuvautuivat unen aikaiset liiakahdukset, joihin liittyy usein siirtyminen univaiheesta toiseen.

Kuvissa 9 ja 10 on esitetty muutamien valve- ja unijaksojen kuvautuminen kartalle.



Kuva 9: Valvejaksoja. Vasemmalla 20 minuuttia TV:n katselua ja keskellä 20 minuuttia kirjan lukemista. Nämä minuutit valittiin EEG:n ja päiväkirjan perusteella. Oikealla yhtenäinen 26 minuutin jakso, jossa koehenkilö käyttää tietokonetta (keltainen klusteri) ja lähtee sen jälkeen kävelylle (syaani klusteri). Pisteiden koko kuvaa kyseiseen karttayksikköön kuvautuneiden minuuttien määrää.



Kuva 10: Unijaksoja. Vasemmalla 20 minuuttia REM-unta ja keskellä 20 univaiheisiin S3 ja S4 kuuluvaa minuuttia. Nämä valittiin EEG:n avulla. Oikealla 36 minuutin yhtenäinen nukkumaanmenojakso, jossa koehenkilö vaipuu torkkumisen jälkeen kevyeen uneen, mitä näyttää seuraavan pikainen käynti syvämmässä unessa, liikkahdus ja siirtyminen takaisin REM- tai S1-uneen.

## 6 Kommentteja

Menetelmä näyttää soveltuvan hyvin vireystasojen visualisointiin ja erotteluun, ja erottelee toisistaan luotettavasti ainakin uni- ja valvetilat. Epämääräisyyttä aiheuttaa minuutin aikajakso, joka on ehkä hieman liian pitkä; monet datapisteet esittävät itse asiassa keskiarvoa erilaisista tiloista.

Kahden EMG-kanavan käyttö oli hyödyllistä ainakin tämän koehenkilön tapauksessa. Submentaalin EMG näyttää rentoutuvan helpommin ja auttaa rentojen valvetoimintojen erottelussa. Toisaalta tämän lihaksen käyttäytymisessä on viitteen [4] (s. 689) mukaan suurta yksilökohtaista vaihtelua.

Blinkkien tunnistusalgoritmi toimi luotettavasti, ainoastaan suuri määrä artifakteja tuntui vaikuttavan sen toimintaan. Nämä aiheuttivat häiriöitä myös EEG-tehospektriin. Ilmiöt eivät kuitenkaan tässä varsinaisesti aiheuta häiriötä, vaan päinvastoin tuovat erotteluun lisäinformaatiota. Signaaleita tutkimalla voidaan päätellä, missä klustereissa piirteet saavat "todellisia" arvoja ja missä eivät.

Uusien muuttujien käyttöönotto toisi lisää resoluutiota eri tilojen erotteluun. Esim. REM-unen aikaiset silmänliikkeet voitaisiin saada esiin sopivalla silmänliikkeiden tunnistusalgoritmillä. Tämä auttaisi myös valvetoimintojen erottelussa. EEG-tehospektrin käytössä ei välttämättä tarvitsisi rajoittua kahteen komponenttiin, vaan spektri voitaisiin laskea koko EEG:n taajuusalueelta, kuten viitteessä [3] on tehty.

Menetelmän soveltamista ajatellen olisi myös mielenkiintoista tietää, miten useamman mallihenkilön nauhoituksilla opetettua karttaa voitaisiin käyttää "tuntemattoman" koehenkilön polygrafian seurantaan. Tätä on tarkoitus kokeilla jatkossa.

## Viitteet

- [1] Värri et al.: Nonlinear eye movement detection method for drowsiness studies. *International Journal of Biomedical Computing*, 43, 1996.
- [2] Neejärvi et al.: Weighted FMH filters. *Signal Processing*, 31, 1995.
- [3] Joutsiniemi et al.: Topographic patterns of EEG spectra. *IEEE Transactions on Biomedical Engineering*, 42, 1995.
- [4] Ernst Niedermeyer, Fernando Lopes da Silva: *Electroencephalography*. Urban & Schwarzenberg, Baltimore, 1987.
- [5] Vesanto et al.: *SOM Toolbox for Matlab 5*. Helsinki University of Technology Publications in Computer Science, Report A57, Espoo, 2000.
- [6] Teuvo Kohonen: *Self-Organizing Maps*, vol. 30 of Springer Series in Information Sciences. Springer-Verlag, Berlin, 1995.