ERNANE JOSÉ XAVIER COSTA

**Estudo da atividade elétrica cerebral em humanos e bovinos usando
processamento digital de sinais e instrumentação eletrônica**

Tese apresentada à Faculdade de
Zootecnia e Engenharia de
Alimentos para a obtenção do título
de professor livre docente, junto ao
Departamento de Ciências Básicas.

Pirassununga
2005

Ao meu Avô Altivo Xavier da Costa⁺ filho de um homem que conheceu os horrores da escravidão e vislumbrou a esperança da liberdade

À minha Avó Clemência Maria de Jesus⁺ que estava ao meu lado quando do meu primeiro passo

Ao meu pai Valdemar Xavier da Costa⁺ que cego pelo analfabetismo morreu com a honra de quem trabalhou a vida inteira.

Aos meus avós maternos Efigênio Fernandez Caldeira⁺ e Maria de Lourdes Moura⁺ que ao vencerem o preconceito permitiram a miscigenação racial da minha família

Aos meus ancestrais

Especialmente ao Povo Brasileiro que mesmo na penumbra de uma vida dura permite a existência da universidade pública e gratuita onde ganho o meu pão de cada dia.

AGRADECIMENTOS

Aos meus filhos José Luquinha e Nicolinha e à mulher que lhes dá carinho, segurança e amor, minha companheira Mariza.

À minha Mãe Odete Fernandez uma mulher de fibra que me ensinou que lutar é preciso, viver não é preciso...

Aos Alunos formandos da primeira turma de Engenharia de Alimentos da USP por me concederem a honra de ser paraninfo.

Aos alunos do LAFAC, Ana Carolina, Kãthery, Rosana, Juliana, Marta, Carine, Ramon, Rodrigo, Samuel, Priscila, Thais, Felipe, Livia, Edson, André, Guilherme.

Aos companheiros de Trabalho do dia-a-dia no LAFAC Prof. Sérgio Paulo Prof. Andrés e o engenheiro Aldo.

A todos os professores e funcionários da FZEA que direta ou indiretamente colaboram com o meu trabalho.

“... A mente é o que o cérebro faz. Especificamente, o cérebro processa informações, e pensar é um tipo de computação. A mente é organizada em módulos ou órgãos mentais, cada qual com um “design” especializado que faz desse módulo um perito em uma área de interação com o mundo. A lógica básica dos módulos é especificada por nosso programa genético...”.

Steven Pinker – Como a mente funciona

RESUMO

COSTA, E.J.X. **Estudo da atividade elétrica cerebral em humanos e bovinos usando processamento digital de sinais e instrumentação eletrônica**. 2005. 92 f. Tese (Livre Docência) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2006.

A atividade elétrica cerebral foi analisada quanto ao seu comportamento no tempo, na frequência e no domínio dos sistemas complexos em dois estudos. Um sobre a aquisição de sinais elétricos cerebrais de bovinos adultos e o outro estudo sobre o padrão da atividade elétrica cerebral durante estímulos gustativos em humanos. Em ambos os estudos, foram usadas técnicas avançadas de instrumentação eletrônica e métodos avançados de processamento digital de sinais. Durante os estudos em bovinos foi desenvolvido um sistema composto de tecnologia sem fio acoplada a um sistema de processamento digital de sinais cujos resultados obtidos permitem concluir que a aquisição de sinais elétricos cerebrais em bovinos adultos é viável. Os estudos realizados com estímulos gustativos levaram a resultados que mostram a existência de padrão no comportamento tempo-frequência da atividade elétrica cerebral dependente dos estímulos doce, salgado e neutro.

Palavras-chave: Telemetria, EEG, Bovinos, wavelets, análise sensorial, complexidade

ABSTRACT

COSTA, E.J.X. Study of brain electrical activity from humans and bovines using digital signal processing and electronics instrumentation. 2005. 92 f.
Thesis (Livres de docencia) – Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2006.

This work uses digital signal processing methods for drawing feature information from human electroencephalogram (EEG) signals aiming at the discrimination among mental tasks during gustatory stimulation and to monitor brain electrical activity of adult bovines. The study with humans shown that single channel EEG records, are able to reveal a significant EEG discrimination among sweet, salty and water tastes. The animal study shown that digital signal processing methodology and instrumentation electronics developed were able to monitor and to characterize bovine brain electrical activity in freely moving animals.

Keywords: Telemetry, EEG, Bovine, wavelets, sensorial analysis, complexity

SUMÁRIO

DEDICATÓRIA

AGRADECIMENTO

EPIÍGRAFE

RESUMO

ABSTRACT

1 INTRODUÇÃO	9
1.1 MOTIVAÇÃO	9
1.2 A ATIVIDADE ELÉTRICA CEREBRAL EM HUMANOS	10
1.2.1 Interface cérebro-computador.....	11
1.2.2 Atividade elétrica cerebral e o sentido gustativo	12
1.2.3 O equipamento de EEG para humanos	13
1.2.4 Eletrodos.....	14
1.3 ATIVIDADE ELÉTRICA CEREBRAL EM BOVINOS.....	17
1.3.1 O crânio bovino.....	18
1.3.2 O EEG bovino e a telemetria.....	21
1.3.3 Características do sinal de EEG de bovinos: uma revisão histórica.....	22
1.4 PROCESSAMENTO DIGITAL DE SINAIS	23
1.4.1 Amostragem de sinais contínuos	25
1.4.2 Teorema da amostragem	27
1.4.3 Densidade Espectral de Potências	27
1.4.4 Representação Gaussiana Adaptativa.....	30
1.4.5 Medidas de complexidade usando transformadas de ondaletas	31
1.4.6 Análise de multiresolução usando ondaletas	32
1.4.7 A transformada de ondaletas.....	35
1.5 OBJETIVOS E HIPÓTESE GERAL DA TESE.....	37
2 MATERIAIS E MÉTODOS	38
2.1 AQUISIÇÃO DE SINAIS CEREBRAIS EM HUMANOS DURANTE ESTÍMULOS GUSTATIVOS. 38	
2.1.1 Paradigma experimental	38
2.1.2 Sistema de aquisição de sinais de EEG durante análise sensorial	40
2.2 AQUISIÇÃO DE SINAIS CEREBRAIS EM BOVINOS	41
2.2.1 Desenvolvimento do equipamento de EEG para bovinos	42
2.2.2 Módulo 1: Amplificação, conversão digital e transmissão do sinal de EEG.....	42
2.2.3 Conversão analógico-digital e software de controle do microcontrolador	44
2.2.4 Módulo 2: Recepção do sinal e interface com o microcomputador.....	45
2.2.5 Teste do equipamento	47
2.2.6 Experimentação animal.....	47
2.2.7 Teste de posição dos eletrodos com animal inconsciente	48
2.2.8 Animal consciente e com liberdade parcial de movimentos.....	50
2.2.9 Animal consciente e com liberdade total de movimentos.....	50
2.2.10 Animais na câmara climática	51
2.2.11 Cortes anatômicos	52

2.3 PROCESSAMENTO DIGITAL DE SINAIS	53
3 RESULTADOS E DISCUSSÃO	54
3.1 CARACTERÍSTICAS DO EEG HUMANO DURANTE ESTÍMULOS GUSTATIVOS.....	54
3.2 CARACTERÍSTICAS DO EEG BOVINO	60
3.2.1 Equipamento de EEG desenvolvido para Bovinos.....	60
3.2.2 Cortes anatômicos do crânio do bovino.....	64
3.2.3 EEG obtido de bovinos totalmente livres dentro do piquete experimental.....	66
3.2.3.1 Medida de complexidade do EEG de animais soltos no piquete na sombra e expostos ao sol.....	72
3.2.3.2 Cálculo dos coeficientes AGR em animais soltos no piquete na sombra e expostos ao sol.....	73
3.2.4 EEG obtido de bovinos em gaiolas dentro e fora da câmara climática.	74
3.2.4.1 Medida de complexidade do sinal de EEG adquirido em bovinos na câmara climática.	78
3.2.4.2 Coeficientes AGR do sinal de EEG adquirido em bovinos na câmara climática.....	79
3.2.5 O sinal de EEG como uma nova variável em experimentos com bovinos.	80
3.3 IMPACTO DOS RESULTADOS NA COMUNIDADE CIENTÍFICA INTERNACIONAL.	81
3.3.1 Publicação número 1 – Aquisição de EEG em humanos	81
3.3.2 Publicação número 2 – Atividade elétrica cerebral em humanos durante estímulos gustativos.....	82
3.3.3 Publicação número 3 – Aquisição de sinais de EEG em bovino usando biotelemetria.....	82
CONCLUSÃO.....	84
REFERÊNCIAS	85
ANEXO A – PUBLICAÇÃO NÚMERO 1.....	90
ANEXO B – PUBLICAÇÃO NÚMERO 2.....	91
ANEXO C – PUBLICAÇÃO NÚMERO 3.....	92

1 INTRODUÇÃO

Neste capítulo será apresentada a descrição geral do tema da tese. Na seção 1.1 será apresentada a motivação para o estudo dos sinais elétricos cerebrais. Nas seções 1.2 e 1.3 serão apresentados os estudos realizados em humanos e bovinos, respectivamente. Na seção 1.4 serão abordados os fundamentos do processamento digital de sinais e na seção 1.5 será apresentado o objetivo da tese.

1.1 *Motivação*

Nas últimas duas décadas, o trabalho em neurociência cognitiva vislumbrou novos paradigmas, pois o desenvolvimento de novas técnicas para observar o cérebro, visando conhecer sua estrutura e função, permite agora associar um comportamento clínico ou experimentalmente observado, não só a um correlato mental presumido desse comportamento, mas também a marcadores específicos da atividade mental. Pode-se, por exemplo, postular que determinadas regiões cerebrais operam de determinada maneira, podendo-se assim, prever os tipos de mudanças que devem ocorrer na atividade cerebral quando da excitação de uma área específica. O aumento ou a diminuição da atividade cerebral pode ser visualizado por técnicas como a tomografia por emissão de pósitrons (TEP), ressonância magnética funcional (RMf), medidas da atividade magnética cerebral (Magnetoencefalografia - MEG) e medidas da atividade elétrica cerebral (Eletroencefalografia - EEG). Notavelmente, a possibilidade de estabelecer encadeamentos complexos para o entendimento da atividade cerebral não se encerra na aplicação dessas técnicas, pois, pode ser ampliado através da conexão com novas áreas do conhecimento.

Com o aumento do poder da computação, o estabelecimento de uma conexão entre o conhecimento funcional do cérebro (através das técnicas já descritas) e as técnicas avançadas de processamento digital de sinais, possibilitou a interação do cérebro com sistemas computacionais. Esta é a motivação principal deste trabalho, usar a atividade elétrica cerebral como um canal de informação entre o cérebro e um sistema computacional e a partir deste canal de comunicação estudar diversos eventos de estímulo-resposta que possam ser usados na experimentação animal e na análise dos sinais de EEG durante estímulos gustativos.

1.2 A atividade elétrica cerebral em humanos

A atividade elétrica cerebral em humanos começou a ser investigada sistematicamente em 1929, mas foi na década de 50, com o avanço dos dispositivos eletrônicos que foi possível medir quantitativamente e de forma não invasiva, os sinais elétricos cerebrais com amplitudes da ordem de micro volts. Com esse avanço tecnológico o passo seguinte foi o de integrar diversas áreas do conhecimento desde a neurofisiologia até a engenharia biomédica passando por física, eletrônica e computação. Esta integração possibilitou o estudo detalhado dos sinais elétricos cerebrais dentro de um panorama empírico quantitativo de causa-efeito. Ao registro gráfico da variação da amplitude da atividade elétrica cerebral em função do tempo deu-se o nome de eletroencefalograma.

O padrão da atividade elétrica cerebral é determinado pelo nível da atividade encefálica no momento que o sinal é adquirido. A intensidade dos sinais cerebrais é resultante, principalmente, do número de neurônios que disparam em sincronismo e, não do nível total da atividade elétrica do encéfalo, ou seja, os sinais elétricos disparados de forma assíncrona contribuem com uma intensidade muito baixa no EEG.

O EEG sugere que a atividade elétrica cerebral é oscilatória e contínua. Esta atividade oscilatória é dependente do nível de atividade do cérebro. Estas oscilações presentes no EEG são normalmente irregulares e nenhum padrão pode ser identificado considerando apenas a variação do EEG no tempo. Entretanto, podem ocorrer padrões no domínio do tempo em pessoas com algumas disfunções cerebrais como a epilepsia, ou em pessoas normais em alguns estados específicos, por exemplo, durante o sono.

Apesar desta característica predominantemente oscilatória do EEG estudos mostraram que outros tipos de comportamento podem ser observados no EEG em diferentes estados da dinâmica cerebral. Estes estudos mostraram que o sinal de EEG possui características de assimetria temporal, caóticas e não lineares (KOZMA; FREEMAN, 2002).

1.2.1 Interface cérebro-computador

Durantes várias décadas os sinais de EEG foram usados unicamente para fins médicos contribuindo para a elucidação de diversas patologias cerebrais. Em 1991, surge uma aplicação nova para o EEG: uma interface cérebro-computador (WOLPAW et al, 1991). Em 1998, um estudo detalhado mostrou as possibilidades práticas do uso de sinais de EEG em um sistema capaz de reconhecer no EEG padrões diferentes durante a imaginação do movimento da mão para esquerda ou para direita (PFURTSCHELLER et al, 1998). Em 1999, foi demonstrado que pessoas com danos irreversíveis na coluna vertebral, devidamente treinadas, podem através do sinal de EEG escrever usando um “software” no computador (BIRBAUMER et al, 1999). No Brasil pesquisadores da Escola Politécnica (POLI-USP) mostraram que a imaginação do movimento da mão esquerda apresenta padrões no EEG diferentes da imaginação do movimento da mão direita em pessoas normais (COSTA; CABRAL JR, 2000). Atualmente qualquer uso do sinal de EEG em

um sistema computacional pode ser considerado como uma interface cérebro-computador.

1.2.2 Atividade elétrica cerebral e o sentido gustativo

Os estímulos gustativos são processados pelo cérebro considerando suas propriedades físicas e qualidades químicas. O EEG pode ser utilizado para estudar as respostas do cérebro a estímulos gustativos (SCHIMDT et al, 2000).

O sinal de EEG adquirido com um único canal pode ser utilizado para monitorar a atividade mental (COSTA, 2000; CINCOTTI et al, 2003) e há indícios que levam a crer que o padrão de EEG muda durante estímulos gustativos. Experimentos utilizando magnetoencefalografia (MEG) foram feitos para localizar a área gustativa do córtex cerebral e analisar diferenças entre os estímulos doce e amargo (KOBAYAKAWA et al, 1996). Outros métodos, baseados em dinâmica não linear mostraram que o sabor da goma de mascar alterava as características não lineares e o domínio de frequências do EEG (YAGYU et al, 1998). Um método satisfatório para coletar sinal de EEG livre de artefatos ainda não foi desenvolvido, mas há importantes resultados relacionando estímulos gustativos a parâmetros de potencial evocado em humanos (KOBAL, 1995).

Avanços nas técnicas de processamento digital de sinais nas últimas décadas, particularmente nas análises tempo-frequência e não-lineares, forneceram novos métodos de acessar a complexidade do sinal de EEG. Recentemente, técnicas de análise no domínio da frequência do sinal (KHADER, 2004) foram aplicadas ao EEG e outras medidas relacionadas, como o potencial relacionado ao evento (HU et al, 2003). Estas técnicas supõem que os dados observados são estacionários em um curto período de tempo (da ordem de 2 ou 3 segundos). No entanto, esta suposição não é eficiente quando o sinal de EEG apresenta não estacionariedades

significativas. No domínio do tempo as análises mais populares são as chamadas dimensões de complexidade (SARBADHIKARI; CHAKRABARTY, 2001) e dinâmica não linear (KOZMA; FREEMAN, 2002). Estes métodos são usados para análise no domínio do tempo ou da frequência separadamente.

Um dos métodos que permite analisar tempo-frequência de um sinal é a Representação Gaussiana Adaptativa (AGR) que foi proposta independentemente por Qian e Chen (1994) e Mallat e Zhang. (1993), e foi usada na tecnologia de radares. O AGR consiste de um centro tempo-frequência ajustável de funções gaussianas elementares $h_p(t)$ que melhor representam o sinal. Este ajuste é realizado através dos coeficientes de projeção Bp que representam a similaridade entre o sinal $s(t)$ e as gaussianas $h_p(t)$. Os coeficientes Bp refletem o comportamento tempo-frequência do sinal e podem ser usados para extração de características de sinais de EEG (COSTA; CABRAL JR, 2000).

1.2.3 O equipamento de EEG para humanos

O equipamento de EEG para humanos (eletroencefalógrafo) é parte de um conjunto denominado de equipamentos eletromédicos. Este conjunto de equipamentos forma um sistema de instrumentação médica (figura 1.1) cujas características são regidas pela norma NBR IEC 601-1 da Associação Brasileira de Normas Técnicas (ABNT). Esta norma reza sobre a segurança e a qualidade em equipamentos eletromédicos. A norma específica para eletroencefalógrafos é a norma NBR IEC 601-2-26. Esta norma reza sobre a segurança e as especificações técnicas de eletroencefalógrafos usados em humanos. Todos os equipamentos de EEG para humanos são submetidos a um ensaio dinâmico para limitação de energia de partes diferentes do equipamento, ensaios de proteção contra os efeitos de uma desfibrilação, ensaios para medir correntes de fuga através do paciente e demais medidas

elétricas relacionadas a terminais de aterramento funcionais conforme estabelece a norma ABNT601-2-26 1997.

Figura 1.1 – Sistema de Instrumentação médica.

De forma geral um equipamento de EEG é composto de um sistema eletrônico formado por amplificadores de instrumentação e filtros ativos capazes de amplificar sinais da ordem de 1 μV volts. Um equipamento de EEG pode possuir de um até 256 canais. Um canal corresponde a um par de eletrodos e o sistema deve conter ainda um eletrodo de referencia ligados ao sistema de amplificação eletrônica e comum a todos os canais.

1.2.4 Eletrodos

Os eletrodos funcionam como uma interface de comunicação entre o corpo humano e o sistema eletrônico que irá medir o sinal. Eletrodos biopotenciais são eletrodos específicos para medir potenciais bioelétricos. O eletrodo biopotencial pode ser tratado como um transdutor elétrico uma vez

que transforma a corrente iônica do corpo humano em uma corrente elétrica que pode ser medida pelo sistema eletrônico.

As características do sinal biológico que será medido usando-se eletrodos diferem de acordo com sua origem, por exemplo, sinais elétricos cerebrais apresentam características oscilatórias e amplitudes diferentes dos sinais elétricos proveniente do coração. Desta forma, a escolha dos eletrodos é fundamental para uma boa medida do sinal biológico.

O EEG pode ser coletado usando-se eletrodos de superfície, o que caracteriza medida não invasiva, ou usando eletrodos de agulha, o que caracteriza medida invasiva. Nesta tese, os eletrodos usados tanto em humanos como em bovinos foram eletrodos de superfície, o que caracteriza a aquisição de sinais biológicos como não invasiva. O contato entre o eletrodo e o escalpo é mediado por um eletrólito. Este eletrólito forma uma interface entre o escalpo e o eletrodo (figura 1.2 (a)). A corrente que atravessa a interface, passando do eletrodo para o eletrólito consiste de:

- elétrons (e^-) movendo na direção oposta àquela da corrente no eletrodo;
- Cátions (C^+) movendo na direção da corrente
- Íons (I^-) movendo na direção oposta a da corrente no eletrólito.

Para que a carga elétrica cruze a interface é necessário que ocorra troca de cargas entre estes componentes. Estas trocas ocorrem por meios de reações químicas na interface.

(a)

(b)

Figura 1.2 – (a) Representação esquemática da interface pele-eletrodo. A seta indica o sentido da corrente iônica. (b) Ilustração de um eletrodo Ag/AgCl.

Quando a corrente elétrica flui entre o eletrodo e o eletrólito, o eletrodo pode ficar polarizado ou não polarizado, este fenômeno permite distinguir entre dois tipos de eletrodos: eletrodos perfeitamente polarizáveis e eletrodos perfeitamente não polarizáveis. Nos eletrodos perfeitamente polarizáveis não existe nenhuma carga que cruza a interface quando a corrente é aplicada, estes eletrodos funcionam como se fossem capacitores. Eletrodos perfeitamente não polarizáveis são aqueles nos quais a corrente atravessa livremente a interface. Na prática os eletrodos são aproximações destas características. Um exemplo de eletrodo perfeitamente polarizável é o eletrodo de platina. O eletrodo Ag/AgCl é o que mais se aproxima de eletrodos perfeitamente não polarizáveis. A figura 1.2 (b) ilustra um eletrodo do tipo Ag/AgCl.

A disposição dos eletrodos na superfície do escalpo segue uma padronização internacional conhecida como sistema internacional 10-20 (JASPER, 1958). O sistema 10-20 tem como objetivo padronizar a disposição dos eletrodos em determinadas áreas da superfície do escalpo independentemente do tamanho do crânio. A figura 1.3 ilustra a disposição dos eletrodos segundo o sistema internacional 10-20.

Figura 1.3 – Sistema internacional 10-20 para disposição de eletrodos.

1.3 Atividade elétrica cerebral em bovinos

No contexto da experimentação animal, medir grandezas relacionadas com algum evento comportamental ou fisiológico é fundamental para a compreensão de diversos aspectos da qualidade e produtividade animal. Dentro deste contexto pode-se destacar a instrumentação biomédica e eletrônica com sendo um novo campo de exploração científica aplicada à experimentação animal. A atividade elétrica do cérebro em animais foi descrita qualitativamente no século XIX, mas sua sistematização em animais de grande porte como os bovinos, ainda continua sendo objeto de investigação científica.

A medida da atividade elétrica cerebral em bovinos é introduzida neste trabalho como uma variável a ser considerada nas investigações científicas do comportamento e da fisiologia dos bovinos. O EEG de bovinos pode ser usado, por exemplo, para auxiliar na compreensão dos muitos fatores que interferem na produtividade animal, principalmente os fatores ambientais e o manejo. Nas condições ambientais de produção bovina, um importante foco de pesquisa está no estudo do estresse animal causado pela sua interação com o ambiente.

Os animais podem sofrer estresse causado por diferentes fatores como, por exemplo, a temperatura. O estresse térmico pode resultar em perdas na produção. Estas perdas são devidas à redução da ingestão de alimentos, redução no ganho de peso e, em casos extremos, até a morte do animal (BROWN-BRANDL et al., 2003; HAHN, 1999; MADER et al., 2002). Os produtores necessitam de informações sobre como e porque seus animais respondem aos desafios climáticos, para tomarem decisões, estabelecer estratégias de atuação e táticas para reduzir as perdas. Para minimizar estas perdas, são usados muitos índices de estresse ambiental, baseados nas frequências cardíaca e respiratória (BROWN-BRANDL et al., 2003), nas temperaturas timpânicas (MADER et al., 2002; HAHN, 1999), retal (CARVALHO et al, 1995) e corporal (LEFCOURT; ADAMS, 1996). Sinha (2003, 2004) propôs uma maneira alternativa para avaliar estresse térmico em ratos através da medida do sinal elétrico cerebral e obteve resultados que indicaram que o EEG cortical é sensível ao calor ambiental.

1.3.1 O crânio bovino

O sinal elétrico cerebral possui amplitude reduzida e a qualidade do sinal depende de um conjunto de fatores. Entre estes fatores, o mais importante é a localização dos pontos onde serão coletados os sinais. Por este motivo, a compreensão da anatomia do crânio bovino é essencial para a escolha do ponto para posicionamento dos eletrodos.

O crânio bovino adulto apresenta formato triangular, devido ao desenvolvimento tardio dos seios paranasais frontais, que invadem os ossos da abóbada craniana, transformando os contornos abaulados da cabeça do bezerro (figura 1.4(a)), na região frontal ampla e achatada do adulto (figura 1.4 (b)). Esta morfologia e a proporção menor do cérebro em relação ao crânio dificultam a aquisição de sinais elétricos cerebrais (EEG) nos animais adultos.

Figura 1.4 – (a) Corte paramediano da cabeça de um bezerro. (b) Corte paramediano de bovino adulto. 1 – Seio paranasal frontal. Adaptado de Dyce, Sack e Wensing (2004).

Na região do osso frontal, encontram-se vários músculos (figura 1.5) cuja movimentação poderia introduzir artefatos no sinal. Há também, os seios paranasais frontais (figura 1.6), que aumentam a distância do eletrodo ao encéfalo, e a localização dos nervos cranianos (figura 1.7), que inviabiliza o posicionamento dos eletrodos na região temporal e torna, assim, a região frontal a melhor opção para colocação dos eletrodos.

Figura 1.5 – Vista lateral do crânio de bovino adulto. Dissecação superficial da cabeça. 1 – Músculo Frontal; 2 – Músculo orbicular do olho; 3 – Músculo Interscutular; 4 – Músculos auriculares rostrais; 5 – Músculos auriculares ventrais; 6 – Músculo retrator do ângulo lateral do olho. Adaptado de Schaller (1999).

Figura 1.6 – Vista dorsal do crânio de bovino adulto. 1 – Seio frontal rostral lateral; 2 – Seio frontal rostral medial; 3 – Seio frontal caudal. Adaptado de Dyce, Sack e Wensing (2004).

Figura 1.7 – Vista lateral do crânio de um bovino adulto. 1 – Nervo cornual; 2 – Linha temporal; 3 – Nervo auriculopalpebral. Adaptado de Dyce, Sack e Wensing (2004).

1.3.2 O EEG bovino e a telemetria

A aquisição de sinais de EEG em animais apresenta certas dificuldades técnicas com relação ao ambiente de estudo. Normalmente o animal é retirado do seu “habitat” e condicionado no local onde é feita a aquisição dos sinais. Segundo Brockway e Hassler (1993), o uso de métodos de contenção durante a experimentação permite que se faça coleta de dados de animais conscientes, mas pode introduzir artefatos relativos ao estresse e causar problemas na interpretação dos dados. Estes autores ainda afirmam que minimizar ou eliminar as fontes de estresse externo é crucial para entender o processo a ser avaliado. Por este motivo, faz-se necessário o uso de um sistema telemétrico, pois a rádio-telemetria permite a medida de sinais biológicos de animais conscientes e que podem se mover livremente (BROCKWAY; HASSLER, 1993). A maior vantagem desta metodologia é que o animal não está estressado, nem devido ao confinamento e nem pela presença humana durante a coleta de dados (GACSALYI; ZABIELSKI; PIERZYNOWSKI, 2000).

1.3.3 Características do sinal de EEG de bovinos: uma revisão histórica

Em 1966, West e Merrick apresentaram um equipamento telemétrico para a aquisição de EEG em grandes animais e os resultados dos testes de seu equipamento com medidas em bovinos, mostrando as características temporais do sinal sem, contudo, fazer menção às características em frequência.

Pouco depois, em 1971, Merrick e Scharp, usando novilhas com idades entre 24 e 29 semanas, encontraram frequências nas faixas de 12 a 16Hz e 24 a 27Hz, dependendo da atividade do animal.

Já Suzuki et al., em 1990, trabalhando com bezerros de dez semanas de idade, afirmaram que, livres de problemas neurológicos e acordados, os animais apresentaram ondas de baixa amplitude (20 a 30 μ V) e baixa atividade (2 a 7Hz), com superimposição de ondas de baixa amplitude e elevada atividade (5 a 10 μ V, 15 a 30Hz).

Também em 1990, Bager et al. usaram o sinal de EEG para estimar o tempo para que cessasse a atividade cortical, após abate do animal, utilizando a densidade espectral de potências, para obter informação sobre as frequências presentes no sinal antes e depois deste evento.

Em 1991 Costa et al., em estudo comparativo entre dois tipos de anestesia, utilizando bezerros, observaram que os dados obtidos dos animais anestesiados eram suavizados e livres de artefatos. Lin et al. (1991), também em estudos de anestesia em bezerros mostraram que nestas condições o sinal adquirido era caracterizado por baixas frequências e amplitudes elevadas, apresentaram também os gráficos do sinal no tempo. Jones e Pettitt (1992) também apresentaram gráficos do sinal de EEG no tempo e, dada a dificuldade em diferenciar sinal e ruído a partir dos padrões obtidos, propuseram um método baseado no uso do periodograma (suavizado) para avaliar diferentes animais.

Em 1998, Takeuchi, Sitizyo e Harada encontraram frequências na faixa de 18 a 30Hz para bezerros entre sete e dez semanas de idade, com os eletrodos posicionados nas regiões frontal e occipital.

1.4 Processamento digital de sinais

A base de sustentação científica desta tese está fundamentada no processamento digital de sinais (PDS). Pode-se afirmar que o processamento digital de sinais distingue-se de outras áreas da computação unicamente pelo fato de usar um sinal como um tipo de dado. Na maioria das vezes este sinal é a forma de “sentir” o mundo real. O processamento digital de sinais é a matemática, o algoritmo e os procedimentos computacionais usados para manipular estes sinais após os mesmos terem sido convertidos em uma forma digital. A figura 1.8 ilustra um diagrama esquemático que resume o conceito de processamento digital de sinais. Neste diagrama, o mundo real emite um sinal que é captado por sensores e acondicionado em transdutores que transformam o sinal real em um sinal elétrico analógico. A seguir este sinal é convertido de analógico para digital através de um conversor analógico-digital (A/D). Uma vez digitalizado o sinal é processado por técnicas de processamento digital de sinais e as características do sinal são comparadas com as observações do mundo real para que estas possam ser compreendidas.

Figura 1.8 – Representação esquemática do conceito do PDS.

As raízes do PDS remontam às décadas de 60 e 70 quando os computadores digitais tornaram-se uma realidade acadêmica. A partir deste ponto o PDS tornou-se uma área de exploração científica em diversos ramos

do conhecimento humano indo da área biológica até à exploração espacial. A figura 1.9 resume as aplicações do processamento digital de sinais.

Figura 1.9 – Diagrama mostrando as áreas de atuação do PDS.

A atividade elétrica cerebral é um sinal que se caracteriza por ser periódico com baixas frequências, compreendidas aproximadamente entre 0,1 e 38Hz. Além disso, este sinal é uma série temporal que apresenta características de não linearidade, de assimetria temporal, não estacionárias, de formas estocásticas e em alguns casos caóticas (KOZMA; FREEMAN, 2002). Com base nestas informações, foram escolhidos métodos de PDS que levam em conta estas características presentes no sinal de EEG proveniente de bovinos e de humanos.

1.4.1 Amostragem de sinais contínuos

Os sinais digitais estão definidos apenas para alguns instantes de tempo específicos; estes instantes de tempo não precisam ser eqüidistantes, mas, para garantir a simetria temporal do sinal, normalmente são escolhidos desta forma.

Um sinal digital pode ser obtido através da amostragem de um sinal analógico. Existem muitas maneiras de se amostrar um sinal, mas a mais usada é a *uniforme* ou *periódica*, ou seja, realizada em intervalos de tempo eqüidistantes, T .

Seja $x_a(t)$ um sinal analógico, para efeito de simplificação, nas deduções necessárias, serão utilizadas oscilações harmônicas de amplitude (A), fase (θ) e freqüência (F). Assim, considerando $x_a(t)$, como:

$$x_a(t) = A \cos(2\pi Ft + \theta) = A \cos(\Omega t + \theta) \quad (1.1)$$

$$\Omega = 2\pi F$$

Defini-se

$$x(n) = x_a(nT), \quad -\infty < n < \infty \quad (1.2)$$

em que n é um número inteiro, $x(n)$ é o sinal discreto obtido ao se tomar amostras de $x_a(t)$ a cada T segundos. T é chamado de *período de amostragem* ou *intervalo de amostragem* e, $1/T = F_s$ é chamada de *freqüência de amostragem*. Assim, $x(n)$ é dado por:

$$x(n) = A \cos(2\pi f n + \theta) = A \cos(\omega n + \theta) \quad (1.3)$$

$$\omega = 2\pi f$$

em que f é a freqüência do sinal digital.

A amostragem periódica estabelece relações entre a variável continua t e a variável discreta n , ou seja:

$$t = nT = \frac{n}{F_s} \quad (1.4)$$

Como consequência da equação (1.4) existe também uma relação entre a variável F (ou $\Omega = 2\pi F$) para sinais analógicos e a variável f (ou $\omega = 2\pi f$) para sinais digitais. Para estabelecer esta relação, considere o sinal analógico.

$$x_a(t) = A \cos(2\pi Ft + \theta) \quad (1.5)$$

que ao ser amostrado periodicamente a uma freqüência de amostragem $F_s = 1/T$ tem-se:

$$x_a(nT) \equiv x(n) = A \cos(2\pi FnT + \theta) = A \cos\left(\frac{2\pi nF}{F_s} + \theta\right) \quad (1.6)$$

Ao comparar a equação (1.6) com a equação (1.3) observa-se que:

$$f = \frac{F}{F_s} \quad (1.7)$$

ou

$$\omega = \Omega T \quad (1.8)$$

Pode-se também verificar, a partir da equação (1.1), que

$$\begin{aligned} -\infty < F < \infty \\ -\infty < \Omega < \infty \end{aligned} \quad (1.9)$$

e, de maneira análoga, pode-se verificar, a partir da equação (1.3), que

$$\begin{aligned} -\frac{1}{2} < f < \frac{1}{2} \\ -\pi < \omega < \pi \end{aligned} \quad (1.10)$$

Com auxílio da equação (1.7), a inequação (1.10) pode ser reescrita como:

$$-\frac{1}{2} < \frac{F}{F_s} < \frac{1}{2} \quad (1.11)$$

Uma vez que, $F_s = 1/T$ a inequação (1.11) pode ser reescrita na forma

$$-\frac{1}{2T} = -\frac{F_s}{2} \leq F \leq \frac{F_s}{2} = \frac{1}{2T} \quad (1.12)$$

que é equivalente a:

$$-\frac{\pi}{T} = -\pi F_s \leq \Omega \leq \pi F_s = \frac{\pi}{T} \quad (1.13)$$

A amostragem periódica de um sinal analógico implica o mapeamento do intervalo infinito de freqüências F em um intervalo finito das freqüências f . O que resulta em:

$$\begin{aligned} F_{\max} &< \frac{F_s}{2} = \frac{1}{2T} \\ \Omega_{\max} &< \pi F_s = \frac{\pi}{T} \end{aligned} \quad (1.14)$$

1.4.2 Teorema da amostragem

Um dos problemas da amostragem de sinais é, dado um determinado sinal analógico, como escolher a frequência de amostragem F_s . Para que isto seja feito corretamente, é necessária a informação sobre as frequências presentes no sinal a ser analisado, mais precisamente, deve-se conhecer a máxima frequência presente no sinal (F_{max}), uma vez que:

$$F_s > 2F_{max} \quad (1.15)$$

em que F_{max} é a maior componente em frequência presente no sinal analógico. Com F_s selecionada desta maneira, qualquer frequência F_i presente no sinal analógico é mapeada em uma senóide de tempo discreto com frequências dadas por:

$$-\frac{1}{2} \leq f_i = \frac{F_i}{F_s} \leq \frac{1}{2} \quad (1.16)$$

Se F_s for escolhida conforme a equação (1.15) todas as componentes em frequência presentes no sinal analógico são representadas sem ambigüidade no sinal digital e a reconstrução do sinal pode ser feita sem distorções, através do uso de uma função de interpolação adequada.

A frequência $F_N \leq 2F_{max}$ é também conhecida como frequência de Nyquist.

1.4.3 Densidade Espectral de Potências

A maioria dos sinais de interesse pode ser decomposta em uma soma de componentes senoidais (frequências). Para a classe dos sinais periódicos, esta decomposição é chamada Série de Fourier; já para a classe dos sinais aperiódicos, é chamada de Transformada de Fourier.

A análise em frequência de um sinal envolve a resolução do sinal em componentes de frequência, compondo um espectro de frequências para o sinal dado. Diferentes formas de ondas têm diferentes espectros e estes podem ser usados para caracterizar o sinal.

O processo para se obter o espectro de um determinado sinal, usando ferramentas matemáticas, é conhecido como análise espectral (PROAKIS; MANOLAKIS, 2002); no entanto, o processo de se obter o espectro de um sinal na prática é conhecido como estimação de espectro, uma vez que o sinal a ser analisado é apenas uma amostra do sinal real. Desta maneira, o espectro obtido é uma estimativa do espectro do sinal original.

Considerando-se $x(t)$ um sinal periódico e contínuo no tempo. Tomando $x(n)$ a sequência obtida ao amostrar-se o sinal $x(t)$ com uma frequência F_s . O período de $x(n)$ é N , ou seja, $x(n) = x(n+N)$. A série de Fourier para $x(n)$ é a combinação linear de N funções exponenciais harmonicamente relacionadas

$$e^{j2\pi kn/N} \quad k = 0, 1, \dots, N-1^1 \quad (1.17)$$

Expressas por

$$x(n) = \sum_{k=0}^{\infty} c_k e^{j2\pi kn/N} \quad (1.18)$$

onde $\{c_k\}$ são os coeficientes de ajuste dos termos da série.

A obtenção da expressão para a série de Fourier, origina-se a partir da seguinte relação:

$$\sum_{k=0}^{\infty} e^{j2\pi kn/N} = \begin{cases} N, & k = 0, \pm N, \pm 2N, \dots \\ 0, & k \neq 0, \pm N, \pm 2N, \dots \end{cases} \quad (1.19)$$

Multiplicando-se os dois lados da equação (1.18) pelo termo $e^{-j2\pi mn/N}$ e manipulando-se algebricamente as equações, obter-se-á uma expressão para os coeficientes $\{c_k\}$. Assim:

$$c_k = \frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-j2\pi mn/N} \quad k = 0, 1, \dots, N-1 \quad (1.20)$$

Têm-se então as expressões para os coeficientes de Fourier em termos do sinal $x(n)$. A expressão mostrada pela equação (1.20) é também conhecida como *Equação de Análise*, assim como a expressão mostrada pela

¹ j é o número imaginário $j = \sqrt{-1}$

equação(1.18) é comumente chamada de *Equação de Síntese*, ou então *Série de Fourier de Tempo-Discreto* (SFTD).

Os coeficientes c_k fornecem uma descrição de $x(n)$ no domínio da freqüência, uma vez que c_k representa a amplitude e a fase associadas a uma determinada componente de freqüência,

$$s_k(n) = e^{j2\pi kn/N} = e^{j\omega_k n} \quad (1.21)$$

em que $\omega_k = 2\pi k/N$.

Como em um sinal periódico as componentes em freqüência estão igualmente espaçadas, tem-se que $s_k(n) = s_k(n+N)$, isto implica que os coeficientes de Fourier c_k , quando avaliados dentro do intervalo $k = 0, 1, \dots, N-1$, também satisfazem a condição de periodicidade. Consequentemente, o espectro de potências de um sinal $x(n)$, com período N , é uma seqüência periódica, com período N e, assim, N amostras consecutivas de um sinal periódico ou seu espectro oferecem uma completa descrição de um sinal no domínio do tempo e da freqüência.

A potência média de um sinal periódico é definida como:

$$P_x = \frac{1}{N} \sum_{n=0}^{N-1} |x(n)|^2 \quad (1.22)$$

Escrevendo-se a equação(1.22) em função dos coeficientes c_k dados pela equação(1.20) tem-se a seguinte expressão para a potência:

$$P_x = \frac{1}{N} \sum_{n=0}^{N-1} x(n)x^*(n) = \frac{1}{N} \sum_{n=0}^{N-1} x(n) \left(\sum_{k=0}^{N-1} c_k^* e^{-j2\pi kn/N} \right) \quad (1.23)$$

Mudando a ordem dos somatórios e fazendo uso da equação (1.20), tem-se:

$$P_x = \sum_{k=0}^{N-1} c_k^* \left[\frac{1}{N} \sum_{n=0}^{N-1} x(n) e^{-j2\pi kn/N} \right] = \sum_{k=0}^{N-1} |c_k|^2 = \frac{1}{N} \sum_{n=0}^{N-1} |x(n)|^2 \quad (1.24)$$

Observando a expressão dada pela equação(1.24), pode-se concluir que a potência média de um sinal periódico é a soma das potências das componentes individuais de freqüência. Na prática a densidade espectral de

potências é determinada utilizando-se métodos numéricos de solução para a equação(1.24) (SMITH, 2003).

1.4.4 Representação Gaussiana Adaptativa

Como a maioria dos sinais encontrados no mundo real oscila no tempo, é importante explorar seu comportamento local simultaneamente no tempo e na frequência. Os métodos mais usados para caracterizar este tipo de sinal são: Expansão de Gabor, “wavelet”s e Transformadas de Fourier de tempo curto (“STFT, Short Time Fourier Transform”). Mas estas expansões estão definidas em intervalos regulares de amostragem e, em muitos sinais, é necessário que as funções elementares sejam flexíveis, de maneira a acomodar diferentes componentes no sinal analisado (QIAN, 2002). O AGR, mapeia um sinal unidimensional $s(t)$ em uma função bidimensional do tempo e da frequência, ou seja, o plano tempo-frequência indica que componentes espectrais estão presentes em cada instante de tempo.

Um sinal $s(t)$ pode ser representado por uma classe de funções localizadas $h_p(t)$, ou seja:

$$s(t) = \sum_{p=0}^{p \max} B_p h_p(t) \quad (1.25)$$

De modo a melhor caracterizar a natureza tempo-frequência de $s(t)$, as funções elementares $h_p(t)$ serão funções Gaussianas normalizadas de variância α_p e centro tempo-frequência (t_p, f_p) ajustáveis.

Os coeficientes B_p são determinados por:

$$B_p = \langle s(t), h_p(t) \rangle \quad (1.26)$$

com $h_p(t)$ dada por:

$$\begin{aligned} h_p(t) &= g_p(t - t_p) \exp\{j2\pi f_p t_p\} \\ g_p(t) &= (\pi\alpha_p)^{-0,25} \exp\left\{-\frac{t^2}{2\alpha_p}\right\}, \end{aligned} \quad (1.27)$$

$$\alpha_p \in \mathbb{R}^+, t_p, f_p \in \mathbb{R}.$$

Os coeficientes B_p refletem a similaridade entre o sinal de EEG, $s(t)$, e as funções $h_p(t)$, isto é, representam um ponto no plano tempo-frequência e, o problema consiste em encontrar as funções elementares $h_p(t)$, dentro do conjunto de funções elementares que são mais similares à $h_p(t)$. O que é equivalente a encontrar:

$$|B_p|^2 = \max_{h_p} |\langle s_p(t), h_p(t) \rangle| \quad (1.28)$$

a equação (1.28) não tem solução analítica, mas pode ser solucionada por meio de algoritmos numéricos.

1.4.5 Medidas de complexidade usando transformadas de ondaletas

A medida de complexidade (LEMPER; ZIV, 1976) define uma quantidade $c(n)$ que mede o número de padrões distintos que devem ser copiados para produzir uma determinada seqüência de símbolos.

Uma maneira formal de se obter resultados analíticos para $c(n)$ é considerar o intervalo fechado $[0,1]$ e criar seqüências binárias representando os números irracionais contidos neste intervalo. Nota-se que a seqüência não é periódica, espera-se portanto que sejam seqüências aleatórias e com complexidade máxima.

Para todo $x \in [0,1]$ a complexidade $c(n)$ das seqüências de zeros e uns que representam a decomposição binária dos irracionais neste intervalo, tende a um mesmo valor, dado por:

$$\lim_{n \rightarrow \infty} c(n) = b(n) \equiv n \frac{n}{\log_2 n} \quad (1.29)$$

onde $b(n)$ oferece o comportamento assintótico de $c(n)$ para seqüências aleatórias. A medida de complexidade pode ser normalizada usando-se a equação (1.30), ou seja:

$$0 \leq \frac{c(n)}{b(n)} \leq 1 \quad (1.30)$$

Para uma seqüência de símbolos de tamanho n , $b(n)$ pode ser calculado como:

$$b(n) = \frac{Hn}{\log_k(n)} \quad (1.31)$$

sendo k o número de símbolos diferentes na seqüência. No caso binário $k=2$. H representa a entropia dada por:

$$H = \frac{-1}{\ln(n)} \sum_{i=1}^n p_i \log(p_i) \quad (1.32)$$

p_i , a probabilidade de ocorrência de um estado i é obtida pela contagem de ocorrências de cada símbolo, dividida pelo total de símbolos na seqüência. Então, a medida de complexidade normalizada $C(n)$ é dada por:

$$C(n) = \frac{c(n)}{b(n)} \quad (1.33)$$

O sinal de EEG não apresenta apenas características no tempo e na freqüência, sabe-se que os sinais de EEG apresentam também comportamento de auto-similaridade e caótico que permite fazer a análise de complexidade do sinal (COSTA, 2000).

Usando da capacidade de auto similaridade do sinal de EEG, pode-se decompor um sinal em várias componentes. Para cada componente pode-se calcular a sua complexidade, o conjunto desta medida de complexidade calculada para cada componente pode ser usado para caracterizar o sinal de EEG. A análise de multiresolução usando transformadas “wavelets” foi usada para decompor o sinal de EEG.

1.4.6 Análise de multiresolução usando ondaletas

As transformadas “wavelets” são técnicas de análise tempo-freqüência revolucionárias no estudo atual de processamento digital de sinais. As “wavelets” podem ser vistas como novas bases para a representação de

funções, constituindo uma nova técnica para a análise de funções no domínio do tempo e da frequência conjuntamente. A análise de multiresolução conferida às “wavelets” (MARCHANT, 2003) mostra que elas possuem capacidade de “zoom” e podem decompor um sinal de EEG em componentes de diferentes escalas. Esta transformada está relacionada com transformações de escala e de auto-similaridade, tal qual a análise fractal (DAUBECHIE, 1992) o que permite analisar sinais governados pela dinâmica não linear. O uso de uma “wavelet” requer um compromisso entre diferentes propriedades tais como suavização, localização espacial, localização de frequência, habilidade para representar funções polinomiais locais, ortogonalidade e simetria.

Na análise de Fourier, toda função $g(x)$ periódica de período 2π e de quadrado integrável, ou seja, $g(x) \in L^2(0, 2\pi)$, é gerada por uma superposição de exponenciais complexas, $\omega_n(x) = e^{jnx}$, $n = 0, \pm 1, \dots$, obtidas por dilatações da função $\omega(x) = e^{jx}$: $\omega_n(x) = \omega(nx)$. O objetivo é estender essa idéia para $L^2(R)$, isto é, gerar esse espaço a partir de uma única função ψ . Isso é conseguido por dilatações (ou compressões) e translações de ψ da forma

$$\psi_{a,b}(t) = |a|^{-1/2} \psi\left(\frac{t-b}{a}\right) \quad (1.34)$$

A função ψ é chamada de *ondaleta-mãe* e usualmente são tomados valores especiais para a e b : $a = 2^{-j}$, $b = k2^{-j}$, $j, k \in Z$ (MORETTIN, 1999).

Dilatações e translações da função mãe ou ondaleta analisadora $\psi(t)$, formam uma base ortogonal que é a base de ondaletas:

$$\psi_{j,k}(t) = 2^{j/2} \psi(2^j t - k) \quad (1.35)$$

As variáveis j e k são inteiros que escalam e dilatam a função ψ para gerar uma família de ondaletas discretas. A escala j indica a largura da ondaleta, enquanto k determina sua posição. As *ondaletas-mãe* são dilatadas por potências de 2 (dois) e transladadas por inteiros.

As ondaletas são particularmente interessantes devido a suas capacidades de auto-similaridade. Uma vez que se tenha informação sobre a ondaleta-mãe, tudo sobre a base passa a ser conhecido (GRAPS, 1995).

Uma das maneiras de se gerar ondaletas é pela função escala ou ondaleta-pai, ϕ , que é uma solução da equação

$$\phi(t) = \sqrt{2} \sum_k l_k \phi(2t - k) \quad (1.36)$$

Essa função gera uma família ortonormal em $L^2(R)$,

$$\phi_{j,k}(t) = 2^{j/2} \phi(2t - k), \quad j, k \in \mathbb{Z} \quad (1.37)$$

Nessas condições ψ pode ser obtida de ϕ por

$$\psi(t) = \sqrt{2} \sum_k h_k \phi(2t - k) \quad (1.38)$$

em que

$$h_k = (-1)^k l_{1-k} \quad (1.39)$$

é a chamada *relação para filtros de quadratura por espelho*. Na realidade, l_k e h_k são coeficientes de filtros passa-alta e passa-baixa, respectivamente, chamados de *filtros de quadratura por espelho*, usados para calcular a transformada de ondaleta discreta. Esses coeficientes são dados por

$$l_k = \sqrt{2} \int_{-\infty}^{\infty} \phi(t) \phi(2t - k) dt \quad (1.40)$$

$$h_k = \sqrt{2} \int_{-\infty}^{\infty} \psi(t) \phi(2t - k) dt \quad (1.41)$$

As equações (1.40) e (1.41) são equações de dilatação. As ondaletas ϕ geram subespaços com diferentes resoluções, a partir do espaço original, o que permite uma análise de multiresolução (MORETTIN, 1999).

A análise de multiresolução (AMR) permite decompor um determinado sinal em diferentes escalas de resolução. A idéia geral da AMR é aproximar uma função f de $L^2(R)$ em vários níveis de resolução. Cada nível de resolução corresponde a um subespaço V_j , constituído de funções aproximadas, sendo que a melhor aproximação é obtida considerando-se a projeção ortogonal de f sobre cada subespaço V_j .

O fato de $V_j \subset V_{j+1}$ significa que ao passar do nível de resolução j (ou escala 2^j) para o nível de resolução $(j+1)$, ganha-se informação (ou adiciona-se “detalhes”). À medida que a resolução aumenta ($j \rightarrow \infty$), a função aproximada converge para a original. Por outro lado, ao aproximar f a níveis de resolução cada vez menores ($j \rightarrow -\infty$), perde-se informação. Ou seja, a aproximação de f converge para a função nula.

Numa AMR, o espaço V_{j+1} é obtido de V_j escalando-se as funções aproximadoras pela razão dos respectivos níveis, ou seja, se

$$f(t) \in V_j \Leftrightarrow f(2t) \in V_{j+1}, \quad \forall j \quad (1.42)$$

1.4.7 A transformada de ondaletas

Para f de $L^2(R)$, a transformada de ondaletas, com respeito a ψ , é definida por

$$(W_\psi f)(a, b) = |a|^{-1/2} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-b}{a}\right) dt, \quad a, b \in R, \quad a \neq 0 \quad (1.43)$$

Note que a transformada é o produto interno de f pela função $\psi_{a,b}$, dada pela equação(1.34).

Supondo que os dados $\mathbf{X} = (X_0, X_1, \dots, X_T)'$, representam observações de uma amostra i.i.d (independente e igualmente distribuída) ou de um processo estocástico e supondo também que $T = 2^M$, $M > 0$ e inteiro. Defini-se como a transformada de ondaletas discreta de $\mathbf{X}$, com respeito à ondaleta-mãe ψ , a equação

$$d_{j,k}^{(\psi)} = \sum_{t=0}^{T-1} X(t) \psi_{j,k}\left(\frac{t}{T}\right) \quad (1.44)$$

que é simbolizada por $d_{j,k}$. Essa transformada é calculada para $j = 0, 1, \dots, M-1$ e $k = 0, 1, \dots, 2^{j-1}$. Contudo, T observações leva a T termos e, na enumeração acima, tem-se $T-1$; logo, os termos restantes são denominados por $d_{-1,0}$.

Pode-se escrever a equação (1.44) na forma matricial

$$\mathbf{D} = \mathbf{W}\mathbf{X} \quad (1.45)$$

supondo as condições de contorno ideais, a transformada é ortogonal e pode ser invertida

$$\mathbf{X} = \mathbf{W}' \mathbf{d} \quad (1.46)$$

em que $\mathbf{W}'$ indica a transposta de $\mathbf{W}$.

O fato importante é que a solução da equação (1.46) não é obtida por meio da equação (1.45) e sim por um algoritmo piramidal de complexidade $O(T)$, consistindo numa seqüência de filtros passa-alta e passa-baixa.

O vetor $\mathbf{X}$ pode ser associado a uma função f sobre o intervalo $[0,1)$, definida por

$$f(t) = \sum_{k=0}^{2^M-1} X_k I_{\left\{\frac{k}{2^M} \leq t < \frac{k+1}{2^M}\right\}} \quad (1.47)$$

Usualmente não se consideram todos os níveis M de resolução, mas sim, um valor J , que corresponde à escala mais grossa, 2^{-J} , ou a parte suave dos dados. Nesse caso pode-se escrever a equação (1.47) como

$$f(t) = \sum_k c_{J,k} \phi_{J,k}(t) + \sum_{j=J}^{M-1} \sum_{k=0}^{2^j-1} d_{j,k} \psi_{j,k}, \quad j \geq J \quad (1.48)$$

A equação (1.48) pode ser escrita em uma forma alternativa. Seja

$$V_J X = \sum_{j < J} d_{j,k} \psi_{j,k} \quad (1.49)$$

a reconstrução parcial dos dados com “estrutura grossa” e

$$W_J X = \sum_{0 \leq k < 2^j} d_{j,k} \psi_{j,k}, \quad j \geq J \quad (1.50)$$

a reconstrução parcial dos dados a partir de termos com nível de resolução j , ou escala 2^{-j} . Então

$$X = V_J X + \sum_{J \leq j < M} W_J X \quad (1.51)$$

é a decomposição de multiresolução de $\mathbf{X}$.

Na prática a implementação de uma transformada de ondaletas discreta constitui-se em convoluir o sinal com um filtro passa-baixas dado pela equação (1.39) e assim, obter os coeficientes denominados de *coeficientes de ondaletas* (coeficientes “wavelet’s”) e com um filtro passa-altas dado pela equação (1.40), denominados de *coeficientes de detalhes*.

1.5 Objetivos e Hipótese geral da tese

Esta tese tem como objetivo apresentar resultados científicos que comprovam a hipótese de que **avançadas técnicas de processamento digital de sinais e instrumentação eletrônica, possibilitam criar uma interface cérebro-computador capaz de extrair informações da atividade elétrica cerebral em bovinos adultos e diferenciar estímulos gustativos em humanos.**

2 MATERIAIS E MÉTODOS

Este capítulo detalha os métodos e equipamentos utilizados nesta tese. A seção 2. 1 descreve o sistema de aquisição de sinais cerebrais em humanos durante estímulos gustativos. A seção 2. 2 trata da aquisição de sinais de EEG em bovinos detalhando o equipamento desenvolvido. A seção 2.3 descreve a metodologia de processamento digital dos sinais adquiridos.

2.1 Aquisição de sinais cerebrais em humanos durante estímulos gustativos.

Nesta seção serão apresentados os métodos e materiais utilizados na aquisição de sinais de EEG em voluntários humanos, não fumantes com idades entre 19 a 38 anos, durante estímulos gustativos. Também será descrita a instrumentação utilizada bem como detalhes do protocolo experimental.

2.1.1 Paradigma experimental

A aquisição de sinais de EEG durante a análise sensorial de soluções doce e salgada foi realizada com oito voluntários (5 do sexo masculino e 3 do sexo feminino). Cada voluntário participou de 3 sessões experimentais de uma hora. Cada sessão experimental consistiu de 12 repetições. O EEG foi amostrado de forma não invasiva na superfície do escalpo. Os eletrodos utilizados foram eletrodos tipo disco de prata com uma camada de cloreto de

prata (eletrodos Ag/AgCl). Os eletrodos foram dispostos nas posições C3-C4 segundo o sistema internacional de disposição de eletrodos (sistema 10-20). A figura 2.1 mostra a disposição dos eletrodos.

Figura 2.1 – Representação esquemática da disposição dos eletrodos. A1 representa o eletrodo terra.

Os voluntários foram acomodados dentro de um cabine blindada contendo um equipamento de EEG de dois canais da EMSA equipamento médicos Ltda. A aquisição do sinal de EEG foi realizada três segundos após o voluntário colocar a solução na boca. O tempo total de cada aquisição foi de 5 segundos. Os sinais de EEG foram amostrados a 128Hz e após serem amplificados, passaram por um banco de filtros incluindo um filtro “notch” centrado em 60Hz.

Os estímulos gustativos usados foram: uma solução 0.3M de sacarose, uma solução 0.3M de cloreto de sódio (NaCl) e como controle água destilada. Após a degustação de cada solução a língua do voluntário foi lavada com uma solução de água destilada por 10 segundos. O estímulo gustativo foi aplicado usando as soluções na seguinte ordem: o voluntário degustava primeiro a solução de sacarose (estímulo doce), a seguir ele degustava água destilada (estímulo neutro), na sequência degustava a solução de NaCl (estímulo salgado) e em seguida degustava novamente a água destilada, repetindo-se o ciclo até completar todas as medidas do experimento.

2.1.2 Sistema de aquisição de sinais de EEG durante análise sensorial

O sistema de aquisição de sinais de EEG durante a análise sensorial constitui-se de uma cabine blindada devidamente aterrada ligada a um equipamento de EEG controlado por computador. O sistema pode amostrar sinais de EEG em dois canais simultaneamente. O software de controle foi escrito em linguagem C++ e disponibiliza os sinais no formato texto padrão ASCII. O software controla uma placa conversora de sinais analógicos para sinais digitais (A/D) de 32 canais com multiplexação de 20 KHz por canal. Além da amplificação do sinal de EEG no canal o software permite controlar, usando recursos da placa conversora A/D, uma amplificação adicional do sinal de EEG.

Todas as ferramentas de processamento digital de sinais foram codificadas em linguagem C++ usando-se o compilador Borland C++ 6.0 Professional®. Algumas bibliotecas próprias do sistema de análise foram escritas em C++ padrão ANSI e compiladas no compilador DJGPP para plataforma Windows® e GCC para plataforma Linux distribuição Slackware. A figura 2.2 ilustra o sistema de aquisição de EEG de humanos durante a aplicação de estímulos gustativos.

Figura 2.2 – Sistema de aquisição de sinais de EEG durante estímulos gustativos.

2.2 Aquisição de sinais cerebrais em bovinos

Nesta seção serão apresentados os métodos e materiais para a aquisição de sinais de EEG em bovinos adultos. Será descrito em detalhes o desenvolvimento do equipamento de EEG em bovinos. Também serão descritos os métodos de processamento digital de sinais utilizados e o protocolo da experimentação animal.

2.2.1 Desenvolvimento do equipamento de EEG para bovinos

O equipamento de aquisição de dados foi desenvolvido segundo as normas padrões de segurança e qualidade para equipamentos médicos, utilizando-se para isso componentes eletrônicos especificamente desenvolvidos para esta área da instrumentação. O sistema desenvolvido constitui-se de dois módulos: o módulo um, de amplificação e transmissão do sinal de EEG e, o módulo dois de recepção e conexão do sistema com o computador.

Uma inovação importante no equipamento de aquisição de dados foi a incorporação de uma interface “universal serial bus” (USB) com tecnologia de integração totalmente realizada no laboratório de física aplicada e computacional (LAFAC). Esta interface permite tanto a conexão do equipamento via protocolo USB direto ou através de uma interface RS232 convertida para USB. Desta forma caso o computador não tenha uma interface serial o sistema pode ser conectado à USB cabendo ao software desenvolvido toda a tarefa de gerenciamentos da conversão de RS232 para USB 1.5.

2.2.2 Módulo 1: Amplificação, conversão digital e transmissão do sinal de EEG

O módulo 1 ou módulo de coleta sofreu melhorias na segunda etapa do projeto tornando-se um equipamento versátil capaz de ser implementado com vários tipos de sensores a fim de tornar o monitoramento animal mais completo e preciso.

Um microcontrolador gerencia o funcionamento do sistema, isto é, digitaliza os sinais analógicos de até 8 sensores, coleta os dados de sensores ligados a um barramento I2C, e os armazena em uma memória EEPROM,

processa comandos enviados pelo equipamento base e transmite informações através de um transceptor ligado a sua porta UART. A figura 2.3 mostra um diagrama de blocos do módulo 1 equipado com um canal amplificador de EEG e um sensor de temperatura acoplado.

Figura 2.3 – Diagrama de blocos do módulo 1.

O circuito é alimentado por duas baterias de 9V que lhe proporcionam uma autonomia de aproximadamente 48 horas em funcionamento contínuo.

O amplificador de EEG utilizado foi o desenvolvido na primeira etapa do projeto. Permite amplificar em até 10000 vezes a tensão resultante da atividade elétrica cerebral e dispõe de filtros passa alta, passa baixa e um filtro “notch” centrado em 60Hz. A figura 2.4 mostra o diagrama de blocos do canal de EEG.

Figura 2.4 – Diagrama de Blocos do Amplificador de sinais de EEG.

2.2.3 Conversão analógico-digital e software de controle do microcontrolador

Na segunda etapa do projeto o conversor A/D e o sistema de controle microprocessado sofreram alterações importantes. O numero de bits do conversor A/D foi aumentado de 10bits para 12bits e o microcontrolador usado passou a ser o 16F877A com 44 pinos em uma cápsula tipo QFP. O software de aquisição de dados foi escrito em linguagem de assembler e gravado no 16F877A usando o programa de desenvolvimento da Microship®.

Transmissão dos dados

O sistema de telemetria desenvolvido apresenta baixo consumo e alta capacidade de recepção, sendo assim, optou-se pelo uso do transceptor BIM2-433-160 (2005) da Radiometrix®, que é ideal para transmissões bidirecionais a até 200m. O dispositivo BIM2 apresenta um consumo menor que 20 mA a 3 V, é bastante compacto e transmite dados a 64 kbps. A figura 2.5 mostra o diagrama de pinos do dispositivo BIM2, juntamente com suas dimensões.

Figura 2.5 – Disposição dos pinos e dimensões do dispositivo BIM2-433-160, extraída do "Data Sheet" do fabricante (Radiometrix® BIM2 data sheet).

A configuração do módulo como transmissor ou receptor foi realizada usando os pinos 15 e 16 do dispositivo conforme a tabela 2.1 a seguir:

Tabela 2.1 – Configuração dos modos de recepção e transmissão do dispositivo BIM2.

Pino 15 TX	Pino 16 RX	Função
1	1	Desligado (<1 μ A)
1	0	Receptor
0	1	Transmissor
0	0	Auto-teste

O dispositivo BIM2 foi acoplado ao dispositivo 16F877A (microcontrolador) através de uma interface RS232.

O módulo 1 através do dispositivo BIM2 pode receber e enviar dados permitindo desta forma uma operação em rede com outros transmissores acoplados em outros animais durante a realização do experimento, bastando para tal uma estação de rádio base que controle o protocolo de comunicação entre os módulos.

2.2.4 Módulo 2: Recepção do sinal e interface com o microcomputador.

Este módulo é responsável pela recepção do sinal enviado pelo módulo 1. Trata-se de um único canal de 433MHz usando como transceptor o BIM2 da Radiometrix[®]. Na primeira etapa o sistema realizava um protocolo de comunicação ponto-a-ponto dedicado, ou seja, só estava recebendo de um único transmissor, entretanto este módulo sofreu melhorias e é capaz de receber sinais de vários transmissores, através da criação do protocolo FBSN ("Floating Base Sensor Network") um protocolo de comunicação que permite o controle total dos módulos transmissores evitando assim perda de informação devido à sobrecarga da capacidade de recepção do canal.

O transceptor de radio frequência do módulo 2 opera em 433MHz. O módulo 2 possui uma inovação em relação ao projeto inicial pois possui uma interface de comunicação com o computador através de uma USB 1.5 e pode também usar uma serial RS232. O sinal modulado é um sinal digital com protocolo serial assíncrono RS232 operando com uma taxa de transferência de 9600 bps. A figura 2.6 mostra o diagrama esquemático do módulo 2 e a figura 2.7 o seu esquema elétrico.

Figura 2.6 – Diagrama esquemático do módulo 2.

Figura 2.7 – Esquema elétrico do módulo 2.

O circuito não usa a sua fonte de alimentação quando operando com o protocolo USB, uma vez que a tensão de +5 V é retirada do próprio USB do computador. Para garantir uma compatibilidade entre os dados recebidos via RS232 e a interface USB, ou ligar o equipamento a um microcomputador, o módulo 2 cria uma porta serial virtual possibilitando a comunicação entre o circuito e o software.

O software foi desenvolvido na linguagem C++ (figura 2.8), e armazena os dados obtidos através da porta USB ou qualquer porta serial em um banco

de dados e é capaz de exportá-los em formato ASCII para serem analisados com outras ferramentas. Interage com o módulo 1 através do módulo 2 enviando comandos codificados requisitando dados dos sensores acoplados.

Figura 2.8 – Tela de visualização do “software” de aquisição de dados.

2.2.5 Teste do equipamento

Nesta etapa do desenvolvimento do projeto foram realizados testes complementares para se avaliar o funcionamento adequado do sistema telemétrico, do módulo 1 e do módulo 2. Os testes consistiram em avaliar a curva de ganho do módulo1 e o comportamento dos filtros.

2.2.6 Experimentação animal

Os experimentos foram realizados no Campus da USP de Pirassununga, no interior do estado de São Paulo, de janeiro a outubro de 2004. Foram

utilizadas oito novilhas da raça Holandesa, com (528 ± 28) kg e, com aproximadamente 2,5 anos, em condições normais de saúde.

Os animais passaram por um período de adaptação de uma semana no piquete experimental e três dias nas gaiolas de contenção, para se habituarem às instalações. Durante o período de adaptação e o período de experimentação os animais receberam água e ração “ad libitum”.

O experimento foi realizado a campo aberto e na câmara climática do campus em acordo com a bioética do Campus de Pirassununga e todo o procedimento foi acompanhado pelo médico veterinário da prefeitura do Campus.

2.2.7 Teste de posição dos eletrodos com animal inconsciente

A disposição dos eletrodos está bem estabelecida para humanos desde a década de 50 (JASPER, 1958), mas não existe uma padronização para animais. Sendo assim um protocolo para testar a posição de eletrodos foi estabelecido. O animal foi mantido por 24 h sem alimentação para ser anestesiado. A anestesia utilizada foi Rompun da Bayer®, na dosagem de 1,0 mL/kg de peso, totalizando 6,0 mL, suficientes para manter o animal em sedação intensa por cerca de 40 min.

Após o animal ser sedado, foi realizada uma tricotomia nos pontos onde os eletrodos seriam posicionados. Foram testadas três posições na região frontal da cabeça dos animais (figura 2.9). As posições para avaliação foram determinadas traçando uma linha do ângulo lateral dos olhos até o ângulo oposto do processo cornual, o cruzamento destas linhas definiu um ponto no centro do osso frontal. Em seguida foi traçada uma reta perpendicular ao plano mediano com aproximadamente 2,5 cm. Lateralmente à linha mediana foram posicionados os eletrodos da posição dois, enquanto os eletrodos da posição

um e três ficaram a 2,0 cm acima e abaixo respectivamente ao eletrodo da posição dois.

Para cada posição foram realizadas coletas de sinal com duração entre 20 e 70 s e, a partir destas coletas, foram selecionados trechos livres de artefato para análise.

Figura 2.9 – Configurações das disposições dos eletrodos: POS1, POS2 e POS3.

O sinal foi amostrado a 100 Hz e alguns trechos, de acordo com suas características no tempo (presença ou não de artefatos produzidos por movimentação do animal), foram selecionados para análise. A densidade espectral de potências foi obtida, utilizando-se janela Hanning com 50% de sobreposição.

2.2.8 Animal consciente e com liberdade parcial de movimentos

No item 2.2.7 foi selecionada uma posição para coleta dos dados, esta posição foi novamente avaliada, agora com o animal livre de medicação, porém preso por um cabresto de corda à cerca, podendo se mover em um semi-círculo de aproximadamente 2 m de raio. A contenção do animal foi feita para que, em caso de uma reação negativa deste ao equipamento ou aos experimentadores, ele pudesse ser facilmente controlado.

O sinal de EEG foi novamente amostrado a 100 Hz, e alguns trechos (com menor quantidade de artefatos) selecionados para análise.

Foram testados cabrestos elásticos e fitas adesivas (comuns e “silver-tape”) para fixação dos eletrodos. Foi testado também o uso de pequenas bolsas, fixas aos animais, como forma de posicionar o equipamento no animal para que a etapa seguinte, em que a coleta de dados seria feita com o animal totalmente livre, pudesse ser executada.

Foram feitos experimentos com uma hora de duração e durante este período foram coletados trechos de 10 a 50 s. O sinal foi avaliado no domínio do tempo (identificação de artefatos), foram selecionados trechos livres de artefato para avaliação no domínio da frequência (densidade espectral de potências).

2.2.9 Animal consciente e com liberdade total de movimentos

Os estudos preliminares permitiram realizar experimentos com animais que podiam se mover livremente.

Os eletrodos foram fixados à cabeça do animal usando fita do tipo “silver tape”, que apresentou bom desempenho para este fim. O equipamento foi acondicionado em bolsa impermeável colada ao dorso do animal, com o animal

totalmente livre, dentro do piquete experimental (100x50 m²). O sinal foi amostrado a 100 Hz e trechos com aproximadamente 2 minutos de duração foram coletados. As coletas foram feitas em dias e horários distintos. Os animais foram divididos em dois grupos um grupo ocupou um piquete sem sombra ficando os animais sob o sol intenso sendo as medidas de EEG realizadas a uma temperatura média de 29,0 °C . O outro grupo ocupou um piquete com sombra e a temperatura variava de acordo com as correntes de convecção sendo a média de 26,0 °C.

2.2.10 Animais na câmara climática

Para controlar a temperatura e monitorar com mais precisão a variação de umidade e luz seis animais foram usados para avaliação na câmara climática. Os animais foram divididos aleatoriamente em dois grupos de três. Um grupo denominado de controle ficou exposto à temperatura e umidade do ambiente, permanecendo em gaiolas de contenção para bovinos e em local com sombra, para os animais controle foi garantido a permanência dos mesmos sempre na zona de conforto térmico. O outro grupo, denominado teste, foi distribuído dentro da câmara climática e confinado em gaiolas de contenção para bovinos.

Em ambos os grupos a temperatura e a umidade do ambiente foram monitorados a cada hora durante 48 horas. Para identificar o estado do animal com relação ao estresse térmico, monitorou-se a frequência respiratória (Fr), a temperatura retal (Tr), a Temperatura ambiente (Ta), a temperatura da câmara (Tc), a umidade relativa ambiente (Ua) e a umidade relativa na câmara (Uc). Estas medidas foram realizadas a cada 15 minutos. Como só foi possível usar uma câmara climática, para garantir que o grupo controle estivesse sempre na zona de conforto térmico foi escolhida a estação de inverno para realizar os experimentos (a zona de conforto térmico para bovinos da raça holandesa compreende temperaturas e umidades típicas da estação do inverno).

O EEG foi medido a cada hora e também durante a identificação do estresse térmico do grupo teste. Nestes períodos também eram amostrados os sinais de EEG dos animais no grupo controle. Cada medida de EEG correspondia a 5 minutos de sinal. A disposição dos eletrodos e do equipamento seguiu o protocolo estabelecido no item 2.2.7

A temperatura da câmara climática variou de 20 °C, zona de conforto térmico, até 38 °C, fora da zona de conforto térmico para a raça holandesa. O grupo controle foi submetido a variação da temperatura ambiente com temperatura mínima média de 15 °C e máxima de 26 °C nos dias da experimentação.

2.2.11 Cortes anatômicos

Após o abate dos animais foram realizados estudos da anatomia do crânio para um melhor entendimento dos resultados da posição dos eletrodos. Os cortes foram feitos no abatedouro escola da Faculdade de Zootecnia e Engenharia de Alimentos de Pirassununga.

Com um dos crânios bovinos foi realizado um corte transversal na altura da região frontal próximo à região de colocação dos eletrodos (POS2), obtendo-se uma imagem seccional do crânio.

Com o outro crânio bovino foi realizado um corte longitudinal, obtendo-se a imagem antimérica (esquerda).

2.3 Processamento Digital de Sinais

Os sinais adquiridos foram processados usando-se as seguintes técnicas de processamento:

1. Análise de Multiresolução usando transformada “wavelet” ou (Transformadas de Ondas) e medida de complexidade: Os sinais digitais adquiridos foram processados usando as transformadas “wavelet” e para cada resolução foi calculado a medida de complexidade. O software desenvolvido em C++ permite o uso de qualquer “wavelet” bastando para isso um arquivo de informação sobre a “wavelet” e os parâmetros que a caracterizam. A complexidade do sinal de EEG, foi calculada usando a metodologia descrita por Costa et al (2000). Nesta metodologia o sinal é decomposto em diferentes níveis usando a transformada “wavelet” e a complexidade de Lempel e Ziv (1976) é então calculada para cada nível de decomposição. O número de decomposições usado foi baseado no trabalho de Costa et al. que mostrou que para sinais biológicos de baixa frequência, como é o caso de sinais de EEG, a partir da sexta decomposição os coeficientes de complexidade ficam constante à medida que se aumenta o nível de decomposição.
2. Transformadas de Fourier. A transformada de Fourier será implementada para dar suporte a outras transformadas, uma vez que ela é uma transformada básica.
3. Representação Gaussiana Adaptativa (AGR) (QIAN; SHEN, 1996). Implementada em C++ para extração de parâmetros que representarão simultaneamente o comportamento tempo e frequência do sinal.

3 RESULTADOS E DISCUSSÃO

Neste capítulo são apresentados e discutidos os resultados obtidos nesta tese. A seção 3.1 apresenta os resultados da metodologia usada em sinais de EEG humanos durante estímulos gustativos. A seção 3.2 relata e discute os resultados obtidos com a experimentação animal. A seção 3.3 apresenta as publicações deste estudo e discute o impacto científico do trabalho na comunidade científica internacional.

3.1 Características do EEG humano durante estímulos gustativos

A figura 3.1 mostra os gráficos dos coeficientes B_p obtidos usando o método AGR para cada voluntário. Cada coeficiente na figura 3.1 é uma média de 12 medidas de EEG para cada estímulo gustativo aplicado. Os coeficientes B_p foram calculados para cada voluntário. A figura 3.1 mostra os resultados dos coeficientes AGR para o voluntário 1.

Figura-3.1 – Coeficientes B_p para o voluntário 1 (média $\pm$ desvio padrão). (○) – água destilada (estímulo neutro); (□) – estímulo salgado; (■) – estímulo doce.

Nota-se na figura 3.1 que, com exceção do coeficiente B_3 (B_p , para $p=3$), todos os outros coeficientes apresentam valores diferenciados para o voluntário 1. A figura 3.2 mostra a média dos coeficientes para o voluntário 2.

Figura-3.2 – Coeficientes B_p para o voluntário 2 (média $\pm$ desvio padrão). (○) – água destilada (estímulo neutro); (□) – estímulo salgado; (■) – estímulo doce.

Para o voluntário 2, nota-se que os coeficientes B_4 , B_5 e B_6 não apresentam uma diferença significativa. Entretanto todos os demais coeficientes apresentam valores distintos para cada tipo de estímulo.

As figuras 3.3 a 3.8 mostram os valores dos coeficientes AGR para os voluntários 3, 4, 5, 6, 7 e 8, respectivamente. Nota-se nestas figuras que para cada voluntário existe um padrão de distribuição dos coeficientes B_p . Isto demonstra a variabilidade da resposta elétrica cerebral no domínio tempo frequência.

Figura-3.3 – Coeficientes B_p para o voluntário 3 (média $\pm$ desvio padrão). (○) – água destilada (estímulo neutro); (□) – estímulo salgado; (■) – estímulo doce.

Figura-3.4- Coeficientes B_p para o voluntário 4 (média $\pm$ desvio padrão). (○) – água destilada (estímulo neutro); (□) – estímulo salgado; (■) – estímulo doce.

Figura-3.5 – Coeficientes B_p para o voluntário 5 (média $\pm$ desvio padrão). (○) – água destilada (estímulo neutro); (□) – estímulo salgado; (■) – estímulo doce.

Figura-3.6 – Coeficientes B_p para o voluntário 6 (média $\pm$ desvio padrão). (○) – água destilada (estímulo neutro); (□) – estímulo salgado; (■) – estímulo doce.

Figura 3.7 – Coeficientes Bp para o voluntário 7 (média $\pm$ desvio padrão). ($\circ$) – água destilada (estímulo neutro); ($\square$) – estímulo salgado; ($\blacksquare$) – estímulo doce.

Figura3.8 – Coeficientes Bp para o voluntário 8 (média $\pm$ desvio padrão). ($\circ$) – água destilada (estímulo neutro); ($\square$) – estímulo salgado; ($\blacksquare$) – estímulo doce.

Os coeficientes B_p representam pontos no plano tempo x frequência, desta forma, cada coeficiente representa a projeção das características presentes no sinal de EEG no domínio do tempo e no domínio da frequência.

Estes resultados revelam que os sinais de EEG podem ser coletados com apenas um canal de EEG. Esta afirmação corrobora com estudos realizados na literatura (COSTA; CABRAL JR, 2000; CINCOTTI et al, 2002).

3.2 Características do EEG Bovino

Tanto o desenvolvimento do equipamento quanto o protocolo experimental são inovações na aquisição de sinais de EEG em bovinos. Portanto, esta seção apresentará resultados detalhados dos teste realizados com o equipamento desenvolvido, bem como, os resultados da experimentação animal e processamento digital dos sinais.

3.2.1 Equipamento de EEG desenvolvido para Bovinos

Levantamento da curva de ganho.

O equipamento foi ligado a um gerador de funções através de um divisor de tensão conforme mostrado no diagrama da figura 3.9.

Figura 3.9 – diagrama esquemático da ligação entre o gerador de funções e o amplificador de EEG

A saída do divisor foi uma tensão senoidal com valor de $20.34\mu V$ pico a pico obtido a partir de um gerador de funções da marca Ediatron com o correto “casamento” de impedância entre o divisor e amplificador de EEG.

A monitoração do sinal de entrada foi feita utilizando um osciloscópio digital Tektronix TDS102 com interface serial. A frequência inicial do sinal de entrada foi de 1Hz e foi gradativamente incrementada até 80Hz.

A coleta dos dados foi feita em intervalos de 2 segundos com incremento na frequência de 5Hz e o sinal obtido no módulo 1 foi enviado por rádio frequência para o módulo 2 possibilitando, desta forma, avaliar o funcionamento da parte telemétrica do sistema. A figura 3.10 mostra a tela do software recebendo os sinais enviados pelo módulo 1.

Figura 3.10 - Tela de visualização do “software” recebendo os sinais do módulo 1.

A partir dos dados obtidos no módulo 2 enviados pelo módulo 1, obteve-se a curva de ganho *versus* frequência do módulo 1 conforme mostra a figura 3.11.

Figura 3.11 – Curva ganho *versus* frequência do módulo 1 construída a partir dos dados recebidos pelo módulo 2.

A Figura 3.12 mostra a resposta dos filtros passa baixa e “notch” de 60Hz .

Figura 3.12 – Atuação do filtro passa baixa e notch (em 60Hz) no módulo 1 obtidos a partir dos dados coletados no módulo 2.

Para verificar o funcionamento do filtro passa alta, o equipamento foi ligado a um gerador de funções de forma similar ao experimento anterior. O sinal amostrado foi composto de pulsos quadrados de 1 segundo de duração e amplitude de $50.85\mu\text{V}$, conforme ilustra a figura 3.13.

Figura 3.13 – Diagrama esquemático da ligação entre o gerador de funções e o amplificador de EEG para testar o filtro passa alta.

A Figura 3.14 mostra a tela de visualização do “software” recebendo o sinal em baixa frequência transmitido pelo módulo 1 após ação filtro passa alta e a figura 3.15 mostra o gráfico do sinal após atuação do filtro passa alta.

Figura 3.14 – Tela de visualização do “software” mostrando a atuação do filtro passa alta no módulo 1 obtidos a partir dos dados coletados no módulo 2.

Figura 3.15 – Gráfico do sinal após atuação do filtro passa alta no módulo 1.

Todos estes testes mostram que o equipamento de EEG e o sistema telemétrico funcionam adequadamente. É importante ressaltar que o equipamento apresenta uma inovação tecnológica: possui um protocolo próprio de comunicação “wireless” que permite que os equipamentos operem como uma rede de sensores. Este protocolo foi testado e os resultados do teste estão descritos em detalhes no anexo 2. Todos os experimentos descritos neste relatório foram realizados usando-se os equipamentos e o protocolo de comunicação FBSN (Floating Base Sensor Network – Anexo 3).

3.2.2 Cortes anatômicos do crânio do bovino

Os cortes anatômicos foram realizados para explicar porque a posição escolhida foi a POS2. A figura 3.16 mostra o corte transversal na altura da região frontal próximo à região de colocação dos eletrodos (POS2), em que pode ser observados os seios paranasal frontal e rostral, localizado dorsalmente ao encéfalo, e também o músculo frontal, localizado dorsalmente ao osso frontal.

Figura 3.16 – Corte transversal do crânio de bovino, vista caudal. Seio paranasal frontal rostral (1). Músculo frontal (2).

A figura 3.17 mostra um corte longitudinal efetuado no outro crânio bovino, onde notamos os seios paranasais rostral e caudal localizados respectivamente no dorso rostral e no dorso caudal ao encéfalo.

Figura 3.17 – (a) Corte longitudinal do crânio de bovino, vista lateral (esquerda). Seio paranasal frontal rostral (1); Seio paranasal frontal caudal. (2); região em que foram posicionados os eletrodos (POS2) (3). (b) Contorno da massa encefálica.

Os resultados dos cortes anatômicos mostram que a região POS2 possui a menor cavidade do seio paranasal e é mais próxima do encéfalo. Este fato explica porque a região escolhida possui menos artefatos. Este fato também explica porque a literatura sobre EEG de bovinos apresenta resultados, em sua grande maioria, com bezerros. Nos bezerros os seios paranasais ainda não estão desenvolvidos.

3.2.3 EEG obtido de bovinos totalmente livres dentro do piquete experimental

A figura 3.18 mostra o sinal de EEG no tempo com os artefatos e a figura 3.19 mostra a densidade espectral de potência deste sinal.

Figura 3.18 – Sinal de EEG proveniente de animal com liberdade total de movimento dentro do piquete experimental. Amostragem feita a 100Hz com animal exposto a sol intenso.

Figura 3.19 – Gráfico da densidade espectral de potências para o sinal original.

A figura 3.20 mostra trechos livres de artefatos, com 5s de duração, obtidos a partir do sinal mostrado na figura 3.18.

Figura 3.20 – Trechos livres de artefatos, com 5s de duração, obtidos a partir de sinal coletado com animal exposto a sol intenso.

As figuras 3.21, 3.22 e 3.23 mostram os gráficos da densidade espectral de potências para os trechos de sinal mostrados na figura 3.20.

Figura 3.21 – Gráfico da densidade espectral de potências para o sinal mostrado na figura 3.20-(a).

Figura 3.22 – Gráfico da densidade espectral de potências para o sinal mostrado na figura 3.20-(b).

Figura 3.23 – Gráfico da densidade espectral de potências para o sinal mostrado na figura 3.20-c.

A figura 3.24 mostra trechos livres de artefatos, com 5s de duração, obtidos a partir de sinal coletado enquanto animal permanecia na sombra.

Figura 3.24 – Trechos livres de artefatos obtidos a partir de sinal coletado com animal na sombra.

As figuras 3.25, 3.26, 3.27 e 3.28 mostram os gráficos da densidade espectral de potências para os trechos de sinal mostrados na figura 3.24.

Figura 3.25 – Gráfico da densidade espectral de potências para o sinal mostrado na figura 3.24-(a).

Figura 3.26 – Gráfico da densidade espectral de potências para o sinal mostrado na figura 3.24-(b).

Figura 3.27 – Gráfico da densidade espectral de potências para o sinal mostrado na figura 3.24-(c).

Figura 3.28 – Gráfico da densidade espectral de potências para o sinal mostrado na figura 3.24-(d).

A análise visual dos espectros de potência mostram que existe uma variação na sua forma devido ao fato do sinal de EEG ser não estacionário. Entretanto, técnicas avançadas de processamento digital de sinais podem ser usadas para retirar informações do sinal de EEG que não dependem da densidade espectral.

3.2.3.1 Medida de complexidade do EEG de animais soltos no piquete na sombra e expostos ao sol

A figura 3.29 mostra a decomposição “wavelet” do sinal de EEG de um dos animais soltos no piquete experimental e na sombra. A figura 3.30 mostra a média da medida de complexidade para 30 amostragens do sinal de EEG na sombra e no sol.

Figura 3.29 – Decomposição do sinal de EEG usando a “wavelet” DB12. Sinal amostrado com o animal na sombra.

Figura 3.30 – Complexidade em função do nível de decomposição “wavelet” (Média de 30 amostras de sinal de EEG $\pm$ Desvio padrão). $\square$ - Animal exposto ao sol $\blacksquare$ - Animal exposto à sombra.

Nota-se na figura 3.30 que a média da medida de complexidade calculada para os sinais de EEG do animal exposto ao sol é diferente, para as quatro primeiras decomposições “wavelet”s, da média dos sinais de EEG do mesmo animal, porém, na sombra. Neste experimento a única variável do ambiente controlada foi o acesso ou não do animal à sombra. Também neste experimento não foi feita a monitoração dos fatores que expressão estresse no animal.

3.2.3.2 Cálculo dos coeficientes AGR em animais soltos no piquete na sombra e expostos ao sol.

Afigura 3.31 mostra o resultado dos coeficientes de projeção tempo-frequência.

Figura 3.31 –Coeficiente AGR (Média de 30 amostras de sinal de EEG $\pm$ Desvio padrão). □ - Animal exposto ao sol ■ - Animal exposto à sombra.

A figura 3.31 mostra que a média dos coeficientes AGR B_p (para p variando de 1 até 10), representando o sinal de EEG do animal à sombra é diferente da média dos coeficientes do mesmo animal, porém exposto ao sol.

3.2.4 EEG obtido de bovinos em gaiolas dentro e fora da câmara climática.

A seguir são mostrados sinais de EEG livres de artefatos adquiridos durante a experimentação animal na câmara climática. A figura 3.32 é o sinal de EEG do animal 1 (AN1) na zona de conforto térmico dentro da câmara climática e apresentando características de conforto ($Tr=37.5$, $Fr=0.6Hz$). A figura 3.33 mostra a densidade espectral do sinal da figura 3.32. A figura 3.34 é o EEG do mesmo animal, porém, fora da zona de conforto térmico e apresentando características de estresse ($Tr = 40^{\circ}C$ e $Fr = 1.5Hz$) e a figura 3.35 mostra a densidade espectral de potência para o sinal da figura 3.34. As figuras 3.36. e 3.37 são sinais de EEG do animal controle AN4 fora da câmara

climática na zona de conforto térmico sem apresentar características de estresse e as figuras 3.38 e 3.39 são os espectros de potência dos sinais da figura 3.36 e 3.37 respectivamente. Os sinais foram amostrados no mesmo instante para diferentes animais. Este procedimento foi realizado com todos os animais durante o experimento na câmara climática.

Figura 3.32 – EEG do animal AN1 coletado na zona de conforto térmico do Animal AN1. $T_c = 22,7^{\circ}\text{C}$, $T_r = 37,5$, $T_a = 24,3^{\circ}\text{C}$, $U_c = 54\%$ e $U_a = 40\%$.

Figura 3.33 – Densidade espectral do sinal de EEG do animal AN1 coletado na zona de conforto térmico. $T_c = 22,7^{\circ}\text{C}$, $T_r = 37,5$, $T_a = 24,3^{\circ}\text{C}$, $U_c = 54\%$ e $U_a = 40\%$.

Figura 3.34 – EEG do animal AN1 coletado fora zona de conforto térmico. $T_c = 34,1^{\circ}\text{C}$, $T_r = 40$, $T_a = 19,3^{\circ}\text{C}$, $U_c = 70\%$ e $U_a = 41\%$.

Figura 3.35 – Densidade espectral do sinal de EEG do animal AN1 coletado fora da zona de conforto térmico. $T_c = 34,1^{\circ}\text{C}$, $T_r = 40$, $T_a = 19,3^{\circ}\text{C}$, $U_c = 70\%$ e $U_a = 41\%$.

Figura 3.36– EEG do animal controle AN4 coletado na zona de conforto térmico. $T_r = 37,5^{\circ}\text{C}$, $T_a = 22,3^{\circ}\text{C}$ e $U_a = 48\%$.

Figura 3.37 – EEG do animal controle AN4 coletado na zona de conforto térmico $T_r = 37,5^{\circ}\text{C}$, $T_a = 19,3^{\circ}\text{C}$ e $U_a = 45\%$.

Figura 3.38 – Densidade espectral do sinal de EEG do animal controle AN4 coletado dentro da zona de conforto térmico nas condições: $T_r = 37,5^{\circ}\text{C}$, $T_a = 22,3^{\circ}\text{C}$ e $U_a = 48\%$.

Figura 3.39 – Densidade espectral do sinal de EEG do animal controle AN4 coletado dentro da zona de conforto térmico. $T_r=37,5^{\circ}\text{C}$, $T_a=19,3^{\circ}\text{C}$, $U_a = 41\%$.

O espectro de potências dos sinais de EEG do animal AN1 sofre variações visualmente significativas quando o animal apresenta sinais de estresse quando comparado com o espectro de potência do sinal de EEG amostrado no animal sem sinais de estresse, ou na zona de conforto térmico. Este fato foi observado nos outros dois animais que estavam dentro da câmara climática. O espectro de potência do animal AN4, animal do grupo de controle, não indica variações significativas uma vez que o animal esteve sempre na zona de conforto térmico e não apresentou sinais de estresse durante os experimentos. Entretanto, estas diferenças não podem ser quantificadas pela análise visual do espectro de potência, o que justifica o uso de técnicas avançadas de processamento digital de sinais.

3.2.4.1 Medida de complexidade do sinal de EEG adquirido em bovinos na câmara climática.

A figura 3.40 mostra os resultados das medidas de complexidade dos sinais de EEG amostrados nas condições de manifestação do estresse térmico do animal e na região de conforto térmico. Neste experimento a temperatura e a umidade do ambiente foram controladas. A temperatura e a frequência respiratória do animal foram monitoradas a cada amostra do sinal de EEG.

Figura 3.40 – Complexidade em função do nível de decomposição “wavelet” (Média de 30 amostras de sinal de EEG $\pm$ Desvio padrão). □ - Animal na zona de conforto térmico ($T_c = 34,1^\circ\text{C}$, $T_r = 40$, $T_a = 19,3^\circ\text{C}$, $U_c = 70\%$ e $U_a = 41\%$.) ■ - Animal fora da zona de conforto térmico e apresentando características de estresse térmico ($T_c = 34,1^\circ\text{C}$, $T_r = 40$, $T_a = 19,3^\circ\text{C}$, $U_c = 70\%$ e $U_a = 41\%$.).

Nota-se na figura 3.40 que não existe diferença estatística entre as médias da medida de complexidade do animal na zona de conforto térmico das médias das medidas de complexidade do sinal de EEG amostrado no animal fora da zona de conforto térmico.

Estes experimentos foram realizados com os animais contidos em gaiola dentro de um ambiente fechado. Este fato pode ter inserido no EEG do animal um componente de estresse que limita a sensibilidade da informação do estresse térmico no sinal de EEG quando analisado pela medida de

complexidade. O mesmo resultado foi obtido com os animais controle, ou seja, mantidos o tempo todo na zona de conforto térmico, porém também contidos em gaiolas.

3.2.4.2 Coeficientes AGR do sinal de EEG adquirido em bovinos na câmara climática

A figura 3.41 mostra o resultado dos coeficientes de projeção tempo-frequência do sinal de EEG amostrado do animal AN1 na zona de conforto térmico e fora da zona do conforto térmico, dentro da câmara climática.

Figura 3.41 – Complexidade em função do nível de decomposição “wavelet” (Média de 30 amostras de sinal de EEG $\pm$ Desvio padrão). □ - Animal na zona de conforto térmico ($T_c = 34,1^\circ\text{C}$, $T_r = 40$, $T_a = 19,3^\circ\text{C}$, $U_c = 70\%$ e $U_a = 41\%$.) ■ - Animal fora da zona de conforto térmico e apresentando características de estresse térmico ($T_c = 34,1^\circ\text{C}$, $T_r = 40$, $T_a = 19,3^\circ\text{C}$, $U_c = 70\%$ e $U_a = 41\%$.).

Tal qual o observado com a medida de complexidade a média dos coeficientes AGR obtido dos animais na câmara climática não são estatisticamente diferentes. Estes resultados foram observados para todos os animais nos experimentos usando a câmara climática. Os animais controle não mostraram nenhuma variação tanto na média dos coeficientes AGR quanto na média da medida de complexidade.

Apesar das condições do ambiente serem bem controladas no experimento na câmara climática, as condições dos animais são críticas. Pode-se através da frequência respiratória e da temperatura retal constatar que o animal está em estresse térmico, mas, não se pode afirmar que o animal esteja livre de outro tipo de estresse, como por exemplo, o estresse causado pelo confinamento dentro da gaiola da câmara climática. Os resultados com os animais livres no piquete experimental não são conclusivos quanto aos efeitos térmicos. O efeito no sinal de EEG pode vir, por exemplo, da resposta cerebral à incidência da luz solar que é menor quando o animal está na sombra.

3.2.5 O sinal de EEG como uma nova variável em experimentos com bovinos.

Os resultados mostram que: i) é possível medir a atividade elétrica cerebral em bovinos usando telemetria; ii) a medida de complexidade e os coeficientes AGR do sinal de EEG adquirido em bovinos totalmente livres e na sombra apresentou um padrão diferente daqueles adquiridos dos mesmos animais expostos ao sol e iii) a análise do sinal de EEG dos bovinos confinados em gaiolas dentro da câmara climática, não apresentou um padrão diferente dos animais controles confinados em gaiolas e fora da câmara climática em nenhuma das técnicas de processamento digital de sinais usadas (medidas de complexidade e coeficientes AGR).

Apesar destes resultados não serem conclusivos quanto aos estudos térmicos, eles demonstram que é possível coletar sinais de EEG de bovinos

adultos em diferentes condições experimentais. Este aspecto cria um importante paradigma na experimentação animal, uma vez que, é possível medir com uma excelente resolução temporal, as respostas elétricas do cérebro do animal. Além disso, os resultados comprovam que é possível medir o EEG de bovinos através da telemetria.

3.3 Impacto dos resultados na comunidade científica internacional.

Esta seção apresenta na íntegra os três principais resultados apresentados para a comunidade científica internacional e publicados em três diferentes periódicos indexados no ISI (International Science Index). Será comentada o impacto destas publicações dentro do contexto de aquisição de sinais cerebrais em humanos utilizando-se um canal de EEG e também sobre a eficiência da tecnologia “wireless” na aquisição de dados fisiológicos durante a experimentação animal.

3.3.1 Publicação número 1 – Aquisição de EEG em humanos

A publicação número 1 (anexo 1) trata de resultados de estudos sobre a possibilidade de usar o método AGR na diferenciação da imaginação do movimento das mãos no sinal de EEG e discute o seu potencial na aplicação a uma interface cérebro-computador para humanos com deficiência neuromotora.

Uma das principais questões a respeito da metodologia apresentada nesta tese com relação à experimentação em humanos está na aquisição de sinais de EEG usando-se apenas um canal. Existem vários resultados na literatura que usam mais que 16 eletrodos (chegando a até 256 eletrodos) disponibilizados em diferentes áreas da superfície do escalpo para medir simultaneamente o sinal elétrico cerebral. Os autores destes trabalhos argumentam sobre a necessidade de obter-se uma informação espacial do

sinal de EEG através de sua disposição na superfície do escalpo Ryynanen et al (2004). O fato da publicação número 1 aqui apresentar resultados usando apenas um eletrodo na superfície do escalpo, pode suscitar críticas aos resultados obtidos. Entretanto em 2003 um grupo do hospital Santa Lúcia em Roma na Itália publicou um trabalho onde foi estudado o uso de uma interface cérebro-computador usando apenas um canal (três eletrodos). Este grupo citou a publicação número 1 como referencia ao uso de um canal e comprovou os argumentos apresentados na publicação número 1 quanto ao uso de apenas um canal de EEG. A publicação número 1 afirma que se a projeção do sinal no tempo e na frequência pode mostrar detalhes no sinal de EEG independente de uma variável com resolução espacial.

3.3.2 Publicação numero 2 – Atividade elétrica cerebral em humanos durante estímulos gustativos.

A publicação número 2 (anexo 2) resume todos os resultados apresentados nesta tese. Esta publicação reforça os resultados da publicação número 1 sobre a questão da quantidade de eletrodos e do uso da informação no tempo e na frequência através do método AGR.

3.3.3 Publicação numero 3 – Aquisição de sinais de EEG em bovino usando biotelemetria

A publicação numero 3 (anexo 3) apresenta à comunidade científica internacional um sistema de aquisição de sinais fisiológicos através da tecnologia “wireless”. Neste artigo um novo protocolo de comunicação “wireless” foi desenvolvido simulado e testado na aquisição de sinais cerebrais

em bovinos adultos. Este foi o primeiro sistema telemétrico capaz de medir sinais de EEG em bovinos adultos. Neste artigo é discutida toda a instrumentação eletrônica, o controle computacional e a experimentação animal na aquisição de sinais elétricos cerebrais de bovinos.

CONCLUSÃO

O objetivo deste trabalho foi o de provar a hipótese de que avançadas técnicas de processamento digital de sinais e instrumentação eletrônica, possibilitam criar uma interface cérebro-computador capaz de extrair informações da atividade elétrica cerebral em bovinos adultos e diferenciar estímulos gustativos em humanos.

A metodologia apresentada nesta tese propiciou resultados que levam à conclusão de que é possível criar uma interface cérebro computador usando técnicas avançadas de processamento digital de sinais e instrumentação eletrônica para extrair informação da atividade elétrica cerebral em bovinos adultos e diferenciar no sinal de EEG humano os estímulos gustativos doce, salgado e neutro.

REFERÊNCIAS

BAGER, F. et al. Comparison of EEG and ECoG for detecting cerebrocortical activity during slaughter of calves. **Meat Science**, Barking, v.27, n.3, p.211-225, 1990.

BIM2-433-160 Data Sheet. 433MHz high speed FM radio transceiver module. Radiometrix Co. (2003). Disponível em: <<http://www.radiometrix.co.uk/dsheets/bim2.pdf> >. Acesso em: 24 jan. 2005.

BIRBAUMER et al. A spelling device for the paralysed. **Nature**, v. 398, n.6725, p.297-298, 1999.

BROCKWAY, B.P.; HASSLER, C.R. Aplication of radiotelemetry to cardiovascular measurements in pharmacology and toxicology. In: SALEM, H.; BASKEN, S.I. (Ed.). **New technologies and concepts for reducing drug toxicities**. Boca Raton: CRC Press, c1993. p.109-132.

BROWN-BRANDL, T.M. et al. Thermoregulatory responses of feeder cattle. **Journal of Thermal Biology**, Oxford, v.28, n.2., p.149-157, 2003.

CARVALHO, F.A. et al. Breed affects thermoregulation and epithelial morphology in imported and native cattle subjected to heat stress. **Journal of Animal Science**, Savoy, v.73, n.12, p.3570-3573, 1995.

CINCOTTI F, et al. Classification of EEG mental patterns by using two scalp electrodes and Mahalanobis distance-based classifiers. **Methods of Information in Medicine**. v.41, n.4, p.337-41, 2002.

COSTA, A.G.D. et al. Haemodinamic, blood gás and blood biochemical changes following chloralhydrate-magnesium sulphate sedation in calves. **Indian Journal of Animal Science**, Haryana, v.61, n.9, p.939-941, 1991.

COSTA, E.J.X. **Interface cérebro-computador usando redes neurais artificiais e técnicas avançadas de processamento digital de sinais**. 2000. 216 f. Tese (Doutorado) – Escola Politécnica, Universidade de São Paulo, São Paulo, 2000.

COSTA, E.J.X.; CABRAL, E.F. Short time fractal dimension for EEG signal processing in brain-computer interface. In: INTERNATIONAL CONFERENCE ON SIGNAL PROCESSING APPLICATION AND TECHNOLOGY, 2000, Dallas. **Proceedings...** Dallas: CMP Media Inc., 2000. CD-ROM.

DAUBECHIE, I. **Ten lectures on “wavelet”s**. Philadelphia: CBMS Lectures notes series - SIAM, 1992.

DYCE, K.M.; SACK, W.O.; WENSING, C.J.G. **Tratado de anatomia veterinária**. Tradução de Fabiana Buassaly e Maria Eugênia Lauritto Siemma. São Paulo: Elsevier, c2004.

GACSALYI, U.; ZABIELSKI, R.; PIERZYNOWSKI, S.G. Telemetry facilitates long-term recording of gastrointestinal myoelectrical activity in pigs. **Experimental Physiology**, New York, v.85, n.2, p.239-241, 2000.

GRAPS, A. An introduction to “wavelet”s. **Signal and Image Processing**. p.50-61. Disponível em: <http://www.amara.com/IEEEwave/IEEEwavelet.html>>. Acesso em: 25 jan. 2005.

HAHN, G.L. Dynamic responses of cattle to thermal heat loads. **Journal of Animal Science**, Savoy, v.77, n. 2, p.10-20, 1999.

HU Y, et al. Application of time-frequency analysis to somatosensory evoked potential for intraoperative spinal cord monitoring. **Journal of Neurol. Neurosurg. Psychiatry**. v.74 n.1, p.82-87, 2003.

JASPER, H.H. The ten-twenty electrode system of the international federation. **Electroencephalography and Clinical Neurophysiology**, Limerick, v.10, n.2, p.371-375, 1958.

JONES, P.N.; PETTITT, A.N. Comparison of EEGs before and after stunning of cattle taking account of animal-to-animal variation. **Journal of Biomedicine**, Berlin, v.34, n.7, p.815-825, 1992.

KHADER P., ROSLER F., EEG power and coherence analysis of visually presented nouns and verbs reveals left frontal processing differences, **Neuroscience . Letter**. v.354 n.2 p.111-114, 2004.

KAVITHA, V.; NARAYANA, D. A chaos-based model for low complexity predictive coding scheme for compression and transmission of electroencephalogram data. **Medical & Biological Engineering & Computing**, Stevanage, v.37, n.3, p.316-321, 1999.

KELLAWAY, P.; PETERSÉN, I. **Quantitative analytic studies in epilepsy.** New York: Raven Press, 1976.

KOBAL G., Gustatory evoked potential in man, **Electroencephalography. Clinical Neurophysiology.** v.62 n.2, p.449-454, 1985.

KOBAYAKAWA L et al. The primary gustatory area in human cerebral cortex studied by magnetoencephalography. **Neuroscience. Letter** v.212 n.3 p.155-158, 1996.

KOZMA R., FREEMAN W. J., Classification of EEG patterns using nonlinear dynamics and identifying chaotic phase transitions. **Neurocomputing**, v.44, p.1107-1112, 2002.

LEFCOURT, A.M.; ADAMS, W.R. Radiotelemetry measurement of body temperatures of feedlot steers during summer. **Journal of Animal Science**, Savoy, v.74, n.11, p.2633-2640, 1996.

LEMPEL A; ZIV J. On the complexity of finite sequences. **IEEE Transaction.** v.(IT-22), p.75-81, 1976..

LIN, H.C. Hemodynamic response of calves to tiletamine-zolazepam-xylazine anesthesia. **American Journal of Veterinary Research**, Schaumburg, v.52, n.10, p.1606-1610, 1991.

LOW-POWER JFET-input operational amplifiers. Disponível em: <<http://www.ges.cz/sheet/t/tl061-64.pdf>>. Acesso em: 24 jan. 2005. Data sheet.

MADER, T.L. et al. Feeding strategies for managing heat load in feedlot cattle. **Journal of Animal Science**, Savoy, v.80, n.9, p.2373-2382, 2002.

MALLAT S., ZHANG Z.. Matching pursuit with time-frequency dictionaries, **IEEE Transaction. on Signal Processing** 41 (12) 3397-3415 1993.

MARCHANT, B.P. Time-frequency analysis for biosystems engineering. **Biosystems Engineering**, San Diego, v.85, n.3, p.261-281, 2003.

MERRICK, A.W.; SCHARP, D.W. Electroencephalography of resting behavior in cattle, with observations on the question of sleep. **American Journal of Veterinary Research**, Schaumburg, v.32, n.12, p.1993-1997, 1971.

MORETTIN, P.A. **Ondas e ondaletas**: da análise de Fourier à análise de ondaletas. São Paulo: Edusp, 1999.

MUMFORD, H.; WETHERELL, J.R. A simple method for measuring EEG in freely moving guinea pigs. **Journal of Neuroscience Methods**, Amsterdam, v.107, n.(1-2), p.125-130, 2001.

PFURTSCHELLER G.et al. Brain-computer communication based on the dynamics of brain oscillations. **Supplements to Clinical Neurophysiology**. v.57 p. 583-591, 2004.

PROAKIS, J.G.; MANOLAKIS, D.G. **Digital signal processing**: principles, algorithms, and applications. 3rd ed. New Delhi: Prentice-Hall, 2002.

QIAN, S. **Introduction to time-frequency and “wavelet”s transforms**. New Jersey: Prentice-Hall, 2002.

QIAN, S.; CHEN, D. **Joint time-frequency analysis**: methods and applications. Upper Saddle River: PTR Prentice Hall, c1996.

_____. Signal representation using adaptive normalized gaussian function. **Signal Processing**, Amsterdam, v.36, n.1, p.1-11, 1994.

RYYNANEN O. R. et al. Effect of electrode density and measurement noise on the spatial resolution of cortical potential distribution. **IEEE Transaction on Biomedical Engineering**. v.51 n.9 p.1547-1554, 2004

SARBADHIKARI S. N., CHAKRABARTY K. Chaos in the brain: a short review alluding to epilepsy, depression, exercise and lateralization, **Medical Engineering & Physics**. v.23 , n.7, p.445-455, 2001.

SCHALLER, O. (Ed.); NASCIMENTO, F.G. (Trad.). **Nomenclatura anatômica veterinária ilustrada**. São Paulo: Manole, 1999. p.101.

SCHIMDT B et al. Slow cortical DC-potential to sweet and bitter tastes in humans, **Physiological. Behavior.** v.71, n.5 p.581-587, 2000.

SINHA RK. Artificial neural network detects changes in electro-encephalogram power spectrum of different sleep-wake states in an animal model of heat stress. **Medical Biological Engineering. Computation.** 2003. v.41, p. 595 – 600.

SINHA R.K. Electro-encephalogram disturbances in different sleep-wake states following exposure to high environmental heat. **Medical Biological. Engineering Computation.** 2004. v.42, p. 282 – 287.

SMITH, S.W. **Digital signal processing:** a practical guide for engineers and scientists. Amsterdam: Newnes, 2003.

SUZUKI, M. et al. Electroencephalogram of Japanese black calves affected with cerebrocortical necrosis. **Japanese Journal of Veterinary Science**, Tokyo, v.52, n.5, p.1077-1087, 1990.

TAKEUCHI, T.; SITIZYO, K.; HARADA, E. Analysis of the electroencephalogram in growing calves by use of power spectrum and cross correlation. **American Journal of Veterinary Research**, Schaumburg, v.59, n.6, p.777-781, 1998.

WEST, J.K.; MERRICK, A.W. A three channel EEG telemetry system for large animals. **Medical and Biological Engineering**, Oxford, v.4, p.273-281, 1966.

WOLPAW J. R et al. An EEG-based brain-computer interface for cursor control. **Electroencephalogr Clin Neurophysiol.** v.78 n.3 p.252-9, 1991.

YAGYU T. et al. Smell and taste of chewing gum affect frequency domain EEG source localizations, **International Journal of Neuroscience.** v.93 n.4, p.205-216. 1998.

ANEXO A – Publicação Número 1

EEG-based discrimination between imagination of left and right hand movements using adaptive gaussian representation

Ernane J.X. Costa^{*}, Euvaldo F. Cabral Jr

Communication and Signal Processing Laboratory, Department of Telecommunications and Control, Escola Politécnica, São Paulo University, São Paulo, SP, Brazil

Received 15 September 1999; received in revised form 31 July 2000; accepted 24 August 2000

Abstract

This article uses the Adaptive Gaussian Representation (AGR) for human electroencephalogram (EEG) feature extraction aiming the discrimination among mental tasks to be used in a brain computer interface (BCI). It does not focus on the AGR time–frequency representation, but rather on their projection coefficients. Ten volunteers were asked to imagine either right or left hand movement, according to a proper visual stimulus. The features of the resulting EEG signals were characterised by extracting AGR coefficients. Classification was carried out using a Multilayer perceptron (MLP) trained with the classical backpropagation algorithm. Overall results show that AGR coefficients representation is able to reveal a significant EEG discrimination between imagination of right and left hand movement with a mean classification performance of $91\% \pm 5.8\%$ achieved for female subjects and $87\% \pm 5.0\%$ achieved for male subjects. © 2000 IPPEM. Published by Elsevier Science Ltd. All rights reserved.

Keywords: EEG; Brain–computer interface; Adaptive Gaussian Representation; Artificial Neural Network

1. Introduction

The human brain is often considered as the most complex biological existent structure. In recent years, technological advances have allowed the measuring of magnetic and electrical fields produced by a large number of neurons which process and transmit information inside the brain. The brain electrical fields captured by a process known as Electroencephalography (EEG), provides excellent temporal resolution, with a low cost. Thus, EEG is currently the most widely used method of assessing brain processes. The other recent application of EEG signals is the communication between the brain and an electronic system (e.g. a computer). Such a system, which transforms signals from the brain into control signals, is known as a “brain–computer interface” (BCI) [1–7].

The method called AGR was independently proposed by Qian et al. [8,9] and Mallat et al. [10], prior to the

’90s as a method for analyzing joint time–frequency signal behavior. The AGR consists, unlike the Gabor expansion [11,12] and the wavelet decomposition [13], of a time–frequency center bandwidth adjustment of the localized Gaussian elementary functions $h_p(t)$ to better match the analyzed signal.

Due to the non-stationarity that the EEG signals possess, time–frequency analysis techniques have been applied to them [14]. Earlier applications were based on the windowed short-time Fourier transform [15]. In the EEG multi-channel analysis, the cross time–frequency distributions have been used which measure the time–frequency coherence [16]. Other methods assess the complex characteristics of EEG signals [4] and are independent of their precise frequency content. This work focused on the AGR coefficients that can reflect the joint time–frequency of EEG signals, and used them for feature extraction. This approach is relevant to real time BCI applications, as illustrated by Pfurtscheller et al. [5] and Barreto et al. [7] results.

^{*} Corresponding author.

E-mail addresses: ernane@lcs.poli.usp.br (E.J.X. Costa), euvaldo@lcs.poli.usp.br (E.F. Cabral Jr).

2. Methods and materials

2.1. Subjects

Ten volunteers (5 females, 5 males, age from 23–40) participated in this study. All subjects were free of medication and central nervous system abnormalities. Each volunteer took part on five sessions during one week (one session per day).

2.2. Data collection and experimental task

In the data collection task, each subject participated in a recording session lasting for about 1 hour. The EEG was recorded with three sintered Ag/AgCl scalp electrodes positioned over the left and right sensorimotor cortex in position C3 and C4 in the 10–20 international system [17]. The signals were recorded with respect to a reference electrode placed over the right mastoid. The impedance between each electrode and the reference was less than 5 k Ω . The EEG signals were amplified, notch filtered at 60 Hz and then sampled at 128 Hz.

Each session consisted of three experimental runs of 50 trials (20 ‘left’, 20 ‘right’ and 10 ‘basal’). During the experiment, the subject looked at a computer screen 50 cm away from him. Each recording was 12 s long and started with the presentation of a circle in the screen. This circle performed either right or left movement and stopped a few seconds later (7 s). Initially, the subject was instructed to relax, where his basal activity was measured. During the circle movement, the subject was instructed to imagine that his hands (left hand if the circle movement was to the left direction or right hand if the circle movement was to the right direction) were pushing the circle. Special effort was made to select single trials completely free of blink artifacts (the subject was instructed not to blink during 5 s, the total time of acquisition). The subjects were instructed to keep their arms and hands relaxed during the recordings.

2.3. AGR coefficients calculation

Following the development in Quian et al. [8], a signal $s(t)$ can be constituted by a class of localized elementary function $h_p(t)$:

$$s(t) = \sum_{p=0}^{\infty} B_p h_p(t) \quad (1)$$

The function $h_p(t)$ is the normalized Gaussian function with an adjustable variance a_p and time–frequency center (t_p, f_p) , and the B_p coefficients are determined by:

$$B_p = \langle s(t), h_p(t) \rangle \quad (2)$$

with $h_p(t)$ represented by the Eq. (3):

$$\begin{aligned} h_p(t) &= g_p(t - t_p) \exp\{j2\pi f_p t\}, \\ g_p(t) &= (\pi \alpha_p)^{-0.25} \exp\left\{\frac{-t^2}{2\alpha_p}\right\} \\ \alpha_p &\in R^+, t_p, f_p \in R \end{aligned} \quad (3)$$

The coefficients B_p reflect the similarity between the signal $s(t)$ and the functions $h_p(t)$, and the problem consists in finding the $h_p(t)$, among the set of the desired elementary functions that were most similar to $s_p(t)$. This is equivalent to find:

$$|B_p|^2 = \max_{\alpha_p, t_p, f_p} \left| \int s_p(t) h_p^*(t) dt \right|^2 \quad (4)$$

In each step p , one elementary function $h_p(t)$ is found. Next the residual $s_{p+1}(t)$ is computed by:

$$s_{p+1}(t) = s_p(t) - B_p h_p(t) \quad (5)$$

It is shown [9] that the residual vanishes if the matches keep on going to carry on the decompositions described by Eq. (4) and Eq. (5).

2.3.1. The matching algorithm

There is no analytical solution to Eq. (4), but it can be numerically approximated. The Eq. (4) can be used as:

$$\begin{aligned} |B_p|^2 &= \max_{\alpha_p, \Delta M_p, \Delta N_p} \left| \sum_i s_p[i] \left(\frac{\alpha_p}{\pi}\right)^{1/4} \exp\left\{\frac{\alpha_p}{2}(i \right. \right. \\ &\quad \left. \left. - m\Delta M_p)^2\right\} \exp\left\{-j\frac{2\pi n\Delta N_p}{L}i\right\} \right|^2 \end{aligned} \quad (6)$$

ΔM_p and ΔN_p denote the time and frequency intervals in a discrete grid with time and frequency center $(m\Delta M_p, n\Delta N_p)$; L denotes the effective length of the Gaussian function $h_p[i]$ with the largest variance. Thus, the matching algorithm used can be described as follows:

Step 1 — for each p do:

1.1 — Construct $R[i]$ by:

$$R[i] = s_p[i] \left(\frac{\alpha_p}{\pi}\right)^{1/4} \exp\left\{\frac{\alpha_p}{2}(i - m\Delta M_p)^2\right\} \quad (7)$$

1.2 — Apply the FFT to computer B_p

$$\begin{aligned} |B_p|^2 &= \max_{\alpha_p, \Delta M, \Delta N} \left| \sum_i R_p[i] W_L^{-n\Delta N_p i} \right|^2 \\ &= \max_{\alpha_p, \Delta M, \Delta N} |FFT(R_p[i])|^2 \end{aligned} \quad (8)$$

Step 2 — Compute the residual with Eq. (5)
 Step 3 — Check if $\|s_p+1\| < \varepsilon$, where ε is a predetermined error threshold
 Step 4 — if $\|s_p+1\| < \varepsilon$ or the number of coefficients found is the desired, then stop.

2.3.2. Classification of AGR coefficients

For classification, a multilayer perceptron (MLP) with three layers of neurons was used, trained with the back propagation algorithm [18]. It has been shown that a three layer MLP can map any couple of real functions with a pre-specified precision [19]. The distribution of neurons is as follows: ten input neurons, five hidden neurons and ten output neurons. In the output layer, the target was the cluster's center of each class (that contained the AGR coefficients) selected by the classical k -means algorithm [20]. In our classification scheme, we first applied k -means for each class separately, assigning the same number of reference vectors to each class. When the best cluster center was found, the MLP training was started. A percentage of 60% of patterns (AGR Coefficients) was used for training and the other 40% for testing.

3. Results

Using AGR coefficients, a significant differentiation between imagination of right and left hand movement was possible. The AGR coefficients for two subjects (female Fig. 1(a) and male Fig. 1(b)) are shown in Fig. 1. The black squares represent the imagination of right hand movement and the white squares represent the imagination of right hand movement.

For each subject, a different behavior was detected. In some subjects (Fig. 1(a)), the coefficients showed a perceptible difference, but in others this difference was not obvious (Fig. 1(b)). In fact, this confirmed the need of more elaborate classification techniques. The AGR coefficients were then clustered using k -means. The best representation of each class (l -means) was used as target for computing the error to the backpropagation algorithm. For all subjects, 5 to 20 coefficients were tested and the best classification score was obtained with 10 coefficients as presented in Table 1.

Statistical analysis of the results was carried out with the F -test [21]. The experiment involving imagination of left hand movement versus right hand movement gives significant ($p < 0.013$) accurate classification. The experiment involving imagination of left hand or right hand movements versus basal activity gives more significant ($p < 0.009$) accurate classification.

Fig. 1. (a) AGR coefficients for a female subject representing four trials: (■) AGR coefficients for imagination of right hand movement; (□) AGR coefficients for imagination of left hand movement. (b) AGR coefficients for a male subject representing four trials; (■) AGR coefficients for imagination of right hand movement; (□) AGR coefficients for imagination of left hand movement.

4. Discussion

The purpose of this work was to investigate an Adaptive Gaussian Representation (AGR model) for features extraction of spontaneous EEG during the imagination of right and left hand movements. The main advantages of the AGR method in comparison to other available methods is the joint time frequency behavior that is reflected in the AGR coefficients which, when used as representative features of EEG signals, were shown to produce significantly good classification results.

It is clear from our results that some subjects achieved at least 95% accuracy. They would therefore be able to immediately use a BCI via our EEG processing and classification. It is worth mentioning that the best results found in the literature are around 90% of correct recognition [5,22] with the help of a biofeedback strategy. Such results are either worse or comparable to ours. The method presented in this work involves no biofeedback training; that speeds up the classification process to about 0.5 sec after the signal acquisition. This work proceeds to test the AGR method with a larger number of normal subjects and with patients having severe spinal

Table 1

Correct prediction rates of the side of imagination of right and left hand movement for 10 subjects (5 female and 5 male). Each input vector has 5 to 20 AGR coefficients

Subject ID	Number of coefficients	% of correct prediction rates	
		Female	Male
1	5	60	45
	8	70	65
	10	90	85
	15	85	85
	20	85	85
2	5	60	60
	8	65	70
	10	80	90
	15	80	95
	20	80	95
3	5	55	55
	8	80	70
	10	95	80
	15	95	80
	20	95	80
4	5	60	65
	8	80	75
	10	95	85
	15	95	85
	20	95	85
5	5	60	60
	8	80	75
	10	95	95
	15	95	95
	20	90	95
Average for ten coefficients		91±5.8	87±5.0

cord injury or spinal dysfunction. Also, biofeedback strategy can be incorporated to the AGR technique considering that the AGR can reveal the statistic temporal variation of the subject's mental commands. Such a procedure would be expected to improve the recognition rates still more.

Acknowledgements

The authors would like to thank Mr Paulo Faria (EMSA/RJ/Brazil) for donation of the EEG equipment. This work was supported by Conselho Nacional de Pesquisa (CNPq — Brazil) under the grant number 143420/96–8.

References

- [1] Vidaw J. Toward direct brain–computer communication, *Ann Ver Biophys Bioeng* 1973;157–80.

- [2] Wolpaw J, McFarland DJ. Multichannel EEG-based brain–computer communication. *Electroenceph Clin Neurophysiol* 1994;90:444–9.
- [3] Kalcher J, Flotzinger D, Neurper CH, Göllly S, Pfurtscheller G. Brain–computer interface II. Towards communication between man and computer based on on-line classification of three different EEG patterns. *Med Biol Eng Comput* 1996;34:382–8.
- [4] Roberts SJ, Penny W, Rezek I. Temporal and spatial complexity measures for EEG-based brain–computer interfacing. *Med Biol Eng Comput* 1999;37(1):93–9.
- [5] Pfurtscheller G, Neuper CH, Flotzinger D, Pregenzer M. EEG-based discrimination between imagination of right and left hand movement. *Electroenceph Clin Neurophysiol* 1997;103:642–51.
- [6] Birbaumer N, Ghanayim N, Hinterberger T, Iversen I, Kotchoubey B, Kübler A, Perelmouter J, Taub E, Flor H. A spelling device for paralysed. *Nature* 1999;398:297–8.
- [7] Barreto AB, Scargle SD, Adjouadi M. Real-time digital EMG/EEG signal processing in a human–computer interface for users with severe motor disabilities. In: *The International Conference on Signal Processing Applications & technology, (ICSPAT)*, 1999.
- [8] Qian S, Chen D, Chen K. Signal approximation via data-adaptive normalized Gaussian functions and its application for speech processing. In: *Proceedings of ICASSP–92, San Francisco, CA*, 1992:141–4.
- [9] Qian S, Chen D. Signal representation using adaptive normalized Gaussian functions. *Signal Processing* 1994;36(1):1–11.
- [10] Mallat S, Zhang Z. Matching pursuit with time–frequency dictionaries. *IEEE Trans Signal Processing* 1993;41(12):3397–415.
- [11] Gabor D. Theory of communication. *J IEE* 1946;93(III):429–57.
- [12] Friefflander B, Porat B. Detection of transient signal by Gabor representation. *IEEE Trans Acoustics, Speech, Signal Processing* 1989;37(2):169–80.
- [13] Mallat S. A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Trans Acoustics, Speech, Signal Processing* 1989;11:674–93.
- [14] Scabassi RJ, Sun M, Krieger DN, Jasiukaitis P, Scher MS. Time–frequency analysis of the EEG signal. In: *Proceedings of ISSP'90, Signal Processing, Theories, Implementations and Applications*, Gold Coast, Australia, 1990:935–42.
- [15] Kellaway P, Petersen I. *Quantitative Analytic Studies in Epilepsy*. New York: Raven Press, 1992.
- [16] Sun M, Tsui FC, Scabassi RJ. Multiresolution EEG source localization using the wavelet transform. In: *Proceedings of IEEE 19th Northeast Biomedical Engineering Conference*, Newark, NJ, 1993:88–91.
- [17] Jasper HH. The ten–twenty electrode system of the International Federation. *Electroencephalogr Clin Neurophysiol* 1958;10:371–5.
- [18] MacCulloch N, Ainsworth WA, Lingard R. Multi-layer perceptrons applied to speech technology. *B Telecom Technol J* 1988;6(2):131–9.
- [19] Girosi F, Poggio T. Networks and the best approximation property. *Biol Cyber* 1990;63:113–5.
- [20] Wilpon JG, Rabiner LR. A modified k-means clustering algorithm for use in isolated word recognition. *IEEE Trans Acoustics, Speech and Signal Processing* 1985;33(3):587–94.
- [21] Kleinbaum DG, Kupper LL, Muller KE. *Applied Regression Analysis and Other Multivariable Methods*. Boston: PWS-Kent, 1988.
- [22] Roberts SJ, Penny WD. Real-time brain–computer interfacing: a preliminary study using Bayesian learning. *Medical Engineering & Computing* 2000;38(1):56–61.

ANEXO B – Publicação Número 2

Letters

EEG pattern discrimination between salty and sweet taste using adaptive Gabor transform

Juliana Cristina Hashida, Ana Carolina de Sousa Silva,
Sérgio Souto, Ernane José Xavier Costa*

Basic Science, Sao Paulo University, Duque de Caxias Norte 225, 13635-900 Pirassununga, Sao Paulo, Brazil

Received 24 January 2005; received in revised form 20 April 2005; accepted 20 April 2005

Available online 8 June 2005

Communicated by R. W. Newcomb

Abstract

This article uses adaptive Gabor transform (AGR) for drawing feature information from human electroencephalogram (EEG) signals aiming at the discrimination among mental tasks during gustatory stimulation. In this study, single-channel EEG records from eight healthy humans were assessed during the application of sweet, salty and distilled water tastes. Muscular, ocular and skin potential activities were controlled. Overall results show that AGR coefficient representations are able to reveal a significant EEG discrimination among sweet, salty and water tastes.

© 2005 Elsevier B.V. All rights reserved.

Keywords: Sensorial analysis; Time–frequency; Brain; Flavors

1. Introduction

Electroencephalography (EEG) is a noninvasive method to measure brain activity. Considering that sensory stimuli are processed by the brain regarding their physical properties and hedonic quality [1], EEG signals can be used to study brain responses to tastes stimuli. Single EEG channel records can be used to monitor mental tasks

*Corresponding author. Tel.: +551935654177; fax: +551935618606.

E-mail address: ernane@usp.br (E.J.X. Costa).

[2,3] and there are some reasons to believe that EEG patterns change during gustatory stimuli. One set of experiments using magnetoencephalography (MEG) was used to estimate the location of the gustatory area in the human cerebral cortex and to analyze differences between sweet and salty stimuli [4]. Other approaches based on nonlinear dynamics show that chewing-gum flavor affects nonlinear EEG characteristics and the frequency domain of EEG source localizations [5]. A satisfactory method to record EEG signals without artifacts has not been developed yet, but there are important results relating tastes stimuli to potential parameters evoked in humans [6].

Developments in digital signal processing during the last decades, particularly the joint time–frequency and nonlinear analyses, provide new methods for the assessment of the complexity of EEG signals. Recently, frequency analysis techniques [7] have been applied to the EEG and other related measures such as evoked potentials [8]. These techniques assume that the observed data are stationary over short periods of time (on the order of 2–3 s). However, this assumption is not effective when the EEG exhibits significant non-stationarities. In time domain analysis the most popular measures are the so-called dimensional complexity [9] and nonlinear dynamics [10]. These methods are used for frequency or time domain analysis. As a method for analyzing joint time–frequency signal behavior, the adaptive Gabor transform (AGR) was independently proposed by Qian et al. [11] and Mallat et al. [12] and used in radar technology. The AGR consists of a time–frequency center bandwidth adjustment of the localized Gaussian elementary functions $h_p(t)$ for better matching of analyzed signals. This work focuses on the AGR coefficients that can reflect the joint time–frequency of EEG signals, and they were used for signal feature extraction.

2. Materials and methods

Eight normal subjects participated in this study (3 females, 5 males, aged 23–38), all subjects were free of medication and were non-smoking. Subjects gave written informed consent prior to the experiments, and the local ethics committee approved the study. In data collection task, each subject participated in a recording session lasting for about 1 h. The EEG was recorded with sintered Ag/AgCl scalp electrodes in position C3–C4 in the 10–20 international system [13]. The EEG signals were amplified, notch filtered at 60 Hz and then sampled at 128 Hz. Each session consisted of six experimental runs of 12 trials (6 non-taste with distilled water, 3 sweet tastes and 3 salty tastes). The tastes stimuli were 0.3 M sucrose and 0.3 M NaCl. Each recording was 5 s long and started 2 s after the subject put the solution in the tongue. The EEG patterns in response to the tastes stimuli were compared with those in the response to distilled water (non-taste). During the periods among stimuli, the tongue was rinsed with distilled water for about 10 s.

The EEG signals were characterized using the AGR that analyzes the joint time–frequency signal behavior [2]. The joint time–frequency map is a one-dimensional signal into a two-dimensional function of time and frequency. The

time–frequency plane gives an indication of which spectral components are present in each time instant. A signal $s(t)$ can be constituted by a class of localized elementary functions $h_p(t)$, i.e.

$$s(t) = \sum_{p=0}^{p_{\max}} B_p h_p(t). \quad (1)$$

In order to characterize the time-varying nature of $s(t)$, let the elementary function $h_p(t)$ be the normalized Gaussian function with an adjustable variance α_p and time–frequency center (t_p, f_p) . The B_p coefficients are determined by

$$B_p = \int s_p(t) h_p^*(t) dt \quad (2)$$

and $h_p(t)$ is given by

$$h_p(t) = g_p(t - t_p) \exp\{2\pi f_p t\}, \quad (3)$$

where $g_p(t)$ is represented by:

$$g_p(t) = (\pi\alpha_p)^{-0.25} \exp\left\{\frac{-t^2}{2\alpha_p}\right\}, \quad (4)$$

where the power 0.25 is part of a normalization factor.

The AGR coefficients B_p reflect the similarity between the EEG signal $s(t)$ and the functions $h_p(t)$, i.e. represent a point on the time–frequency plane. The problem consists of finding the $h_p(t)$ among the set of desired elementary functions that were most similar to $s_p(t)$. It is equivalent to finding

$$|B_p|^2 = \max_{\alpha_p, t_p, f_p} \left| \int s_p(t) h_p^*(t) dt \right|^2. \quad (5)$$

This equation has no analytical solution, but it can be numerically approximated using a matching pursuit algorithm [2]. For each EEG raw data 10 ($p = 10$) AGR coefficients were obtained. More than 10 coefficients is not relevant because the matching algorithm continually decrease the B_p coefficients as p increases because in each step p , one elementary function $h_p(t)$ is found and the next residual $s_{p+1}(t)$ is computed by

$$s_{p+1} = s_p(t) - B_p h_p(t). \quad (6)$$

The residual $s_{p+1}(t)$ vanishes if the matches keep going to carry on the decompositions [11]. So the error of algorithm depends on the number of decompositions.

The Eq. (5) can be used as

$$|B_p|^2 = \max_{\alpha_p, \Delta M_p, \Delta N_p} \left| \sum_i s_p[i] \left(\frac{\alpha_p}{\pi}\right)^{1/4} \exp\left\{\frac{\alpha_p}{2}(i - m\Delta M)^2\right\} \exp\left\{-j\frac{2\pi n\Delta N_p}{L}i\right\} \right|^2, \quad (7)$$

where ΔM_p and ΔN_p denote the time–frequency intervals in a discrete grid with time and frequency center ($m\Delta M_p$, $n\Delta N_p$), and L denotes the effective length of the Gaussian function $h_p[i]$ with the largest variance. Thus, the matching algorithm used can be described as follows:

Step 0: For each decomposition p do:

Step 1: Generate a vector $R[i]$ by

$$R[i] = s_p[i] \left(\frac{\alpha_p}{\pi} \right)^{1/4} \exp \left\{ \frac{\alpha_p}{2} (i - m\Delta M)^2 \right\}. \quad (8)$$

Step 2: Compute

$$R[i] \left(\frac{\alpha_p}{\pi} \right)^{1/4} \exp \left\{ -j \frac{2\pi n \Delta N_p}{L} i \right\}. \quad (9)$$

Step 3: Eq. (9) is a Fourier transform of $R[i]$ so apply the FFT to compute B_p as follow

$$|B_p|^2 = \max_{\alpha_p, \Delta M_p, \Delta N_p} |\text{FFT}(R_p[i])|^2. \quad (10)$$

Step 4: Compute the residual with Eq. (6).

Step 5: Check if the residual match with a predetermined error threshold, then stop. Otherwise increment p and return to Step 1.

3. Results and discussion

This paper uses EEG records from two scalp electrodes placed in central zones (C3, C4 positions of the international 10–20 system) and one reference electrode placed in position A1 (Fig. 1) to access EEG information during gustatory stimulation.

This electrode position was chosen based on the work of Kabayakawa et al. [16], that showed magnetic fields recorded from the brain (Magnetoencephalography-MEG) in response to two tastants 1 M NaCl and 3 mM of saccharin, more activated in the central area of the head in positions C3 and C4. Using the AGR coefficients, a significant differentiation among salty taste, sweet taste and distilled water (non-taste) was achieved in the EEG signals recorded. The AGR coefficients for all eight subjects are shown in Fig. 2.

Each coefficient in Fig. 2 is an average of six trials and represents the time and frequency behavior of the EEG signal. The B_p coefficients were examined for each subject. The results presented in Fig. 2 show that each subject has the coefficient separation and presents significant separation for at least four of them. Subject 1 presents only one $B_p = 3$ coefficient superposition, while Subject 2 presents three superposition $B_p = 4, 5, 6$ and Subject 4 presents four coefficients without separation $B_p = 2, 3, 4, 5$. In general there was separation in $B_p = 7, 8, 9$ and $B_p = 10$, except for Subject 5, which separated only the first three coefficients. These results reveal that time–frequency energy distribution derived from EEG signals might capture features

Fig. 1. Schematic representation of electrodes in positions C3, C4 and reference electrode in A1.

related to the tastes stimuli. Based on the hypothesis that time–frequency behavior of EEG signals recorded from a single channel might carry transient information, Hu et al. [8] used time–frequency methods for the analysis and classification of EEG signals in real-time monitoring. Recently, MEG has been used to localize sources of various brain electrical activities related with gustatory stimuli [14]; this study combined with the methodology used in this work opens a new possibility for the use of EEG signals in studies of gustatory stimuli. The advantage of this method are the increased spectral and temporal resolution of the signal. Several experiments have shown that the time–frequency analysis method provides narrow frequency peaks, permitting more precise frequency identification and enhanced ability in the determination of frequency changes at any EEG signal point [15] and recently, time–frequency analysis of EEG signal was used to characterize in vitro hippocampus ripples [16].

There are several computational models to investigate how the neural mechanism affects EEG patterns [17,18]. However, only time behavior is considered in these models. The results in this study show experimentally that the time–frequency behavior would show important details about the varying signal distributions present in the rhythms of the brain. Hence the EEG time–frequency characteristic can be used in future computational models to simulate the joint time–frequency behavior of EEG signals.

4. Conclusions

The purpose of this work was to investigate the time–frequency behavior of spontaneous single-channel EEG recordings during taste stimulation using the joint

Fig. 2. Average ($\pm$ standard deviation) of time-frequency coefficients B_p for each subject (subjects 1–8). (○)—Distilled water (non-taste stimulus); (□)—salty taste stimulus; (■)—sweet taste stimulus.

time–frequency analysis methodology. It is clear from our results that all subjects achieved different time–frequency behavior for different tastes stimuli (salty, sweet and non-taste). In conclusion, this work has shown that the time–frequency changes to EEG signal are dependent on different tastes stimuli. Although the methodology presented in this work is able to differentiate salty and sweet taste stimuli in EEG signals, future works will investigate other tastes stimuli with a larger number of subjects and use computational models to simulate the joint time–frequency behavior of EEG signal.

References

- [1] B. Schimdt, L. Marshal, M. Hallschmid, C. Eulitz, J. Born, Slow cortical DC-potential to sweet and bitter tastes in humans, *Physiol. Behav.* 71 (5) (2000) 581–587.
- [2] E.J.X. Costa, E.F. Cabral, EEG-based discrimination between imagination of left and right hand movements using adaptive Gaussian representation, *Med. Eng. Phys.* 22 (5) (2000) 345–348.
- [3] F. Cincotti, F. Mattia, C. Babiloni, F. Carducci, L. Bianchi, J.D. Millan, J. Mourino, S. Salinari, M.G. Marciani, F. Babiloni, Classification of EEG mental patterns by using two scalp electrodes and Mahalanobis distance-based classifiers, *Method. Inform. Med.* 41 (4) (2002) 337–341.
- [4] L. Kobayakawa, H. Endo, S. Ayabe-Kanamura, T. Kumagai, Y. Yamaguchi, Y. Kikuchi, T. Takeda, S. Saito, H. Ogawa, The primary gustatory area in human cerebral cortex studied by magnetoencephalography, *Neurosci. Lett.* 212 (3) (1996) 155–158.
- [5] T. Yagyu, I. Kondakor, K.K.T. Kochi, T. Kinoshita, T. Hirota, D. Lehmann, Smell and taste of chewing gum affect frequency domain EEG source localizations, *Internat. J. Neurosci.* 93 (3–4) (1998) 205–216.
- [6] G. Kopal, Gustatory evoked potential in man, *Electroencephalogr. Clin. Neurophysiol.* 62 (6) (1985) 449–454.
- [7] P. Khader, F. Rosler, EEG power and coherence analysis of visually presented nouns and verbs reveals left frontal processing differences, *Neurosci. Lett.* 354 (2) (2004) 111–114.
- [8] Y. Hu, K.D. LuK, W.W. Lu, J.C. Leong, Application of time–frequency analysis to somatosensory evoked potential for intraoperative spinal cord monitoring, *J. Neurol. Neurosurg. Psychiatry.* 74 (1) (2003) 82–87.
- [9] S.N. Sarbadhikari, K. Chakrabarty, Chaos in the brain: A short review alluding to epilepsy, depression, exercise and lateralization, *Med. Eng. Phys.* 23 (7) (2001) 445–455.
- [10] R. Kozma, W.J. Freeman, Classification of EEG patterns using nonlinear dynamics and identifying chaotic phase transitions, *Neurocomputing* 44 (2002) 1107–1112.
- [11] S. Qian, D. Chen, K. Chen, Signal representation using adaptive normalized gaussian functions, *Signal Process.* 36 (1) (1994) 1–11.
- [12] S. Mallat, Z. Zhang, Matching pursuit with time–frequency dictionaries, *IEEE Trans. Signal Process.* 41 (12) (1993) 3397–3415.
- [13] H.H. Jasper, The ten–twenty electrode system of the International Federation, *Electroencephalogr. Clin. Neurophysiol.* 52 (2) (1958) 371–375.
- [14] N. Murayama, N. Nakasoto, K. Hatanaka, S. Fujita, T. Igasaki, A. Kanno, T. Yashimoto, Gustatory evoked magnetic fields in humans, *Neurosci. Lett.* 210 (2) (1996) 121–123.
- [15] M. Sun, M.L. Sheuer, R.J. Scalabassi, Decomposition of biomedical signals for enhancement of their time–frequency distributions, *J. Franklin Inst.* 337 (4) (2000) 453–467.
- [16] L. Kobayakawa, H. Ogawa, H. Kaneda, S. Ayabe-Kanamura, S. Saito, Spatio–temporal analysis of cortical activity evoked by gustatory stimulation in humans, *Chem. Senses* 24 (2) (1999) 201–209.
- [17] Y. Gu, G. Haines, H. Liljenström, B. Wahlund, A cortical network model for clinical EEG data analysis, *Neurocomputing* 58–60 (2004) 1187–1196.
- [18] M. Mazza, W. Tedeschi, M. Pinho, U.P.C. Neves, Tsallis information measure applied to the analysis of EEG signals in a model of the somatosensory system, *Neurocomputing* 44 (2002) 915–921.

ANEXO C – Publicação Número 3

ELSEVIER

Available online at www.sciencedirect.com

SCIENCE @ DIRECT®

Computers and Electronics in Agriculture 49 (2005) 246–254

Computers
and electronics
in agriculture

www.elsevier.com/locate/compag

A wireless floating base sensor network for physiological responses of livestock

Ana Carolina de Sousa Silva, Aldo Ivan Céspedes Arce,
Sérgio Souto, Ernane José Xavier Costa*

Department of Basic Science – ZAB-FZEA, São Paulo University, Pirassununga, SP, Brazil

Received 10 January 2005; received in revised form 20 April 2005; accepted 4 May 2005

Abstract

This article presents a wireless sensor network prototype to monitor physiological responses of livestock. As an example application the bovine brain electrical activity was monitored. The system is a novel low cost wireless communication protocol named Wireless Floating Base Sensor Network (FBSN) protocol. The basic equipment consists of two modules, one positioned at the animal (animal's module) and the other in an observation station (base module). The first one measures physiological responses from digital sensors, digitalizes data, and transmits it to the base module. The base module in turn, using an FBSN protocol, controls data collection from different animal modules and stores the data. The equipment developed and the FBSN protocol were able to monitor bovine brain electrical activity in six free moving animals for a period of 3 days. The system was designed with the ability to monitor any number of animals for a period that depends on physiological measurement and battery lifetime.

© 2005 Elsevier B.V. All rights reserved.

Keywords: Equipment; Protocol; Telemetry; Livestock

1. Introduction

Exporting of animal products accounted for US\$ 6.45 billion in revenue for Brazil in 2004. Many factors interfere with the animals' productivity, such as genetics, nutrition and

* Corresponding author. Tel.: +55 1935654177; fax: +55 1935618606.

E-mail address: ernane@usp.br (E.J.X. Costa).

environmental factors. Environmental conditions in Brazil are a major concern because thermal stress experienced by animals during periods of elevated climatic temperatures may result in reduced feed intake, reduced body weight gain, and in extreme cases, death of cattle (Mader et al., 2002; Brown-Brandl et al., 2003; Hahn, 1999a,b). Consequently, thermal stress results in losses that total up to 10% per year in Brazil. Livestock managers need information about how and why their animals respond to environmental challenges to make improved decisions on strategies and tactics to reduce loss during hot weather. In order to minimize loss, many physiological stress indices are used, such as heart or respiration rate (Brown-Brandl et al., 2003) and tympanic temperature (Hahn, 1999a,b; Mader et al., 2002). Sinha (2003, 2004) proposed an alternative to thermal stress evaluation in rats using brain electrical activity measurement. He found that cortical electroencephalogram (EEG) is sensitive to environmental heat. The system described here can be applied to investigate a possible correlation between environmental heat and bovines' EEG patterns. The system can also be used to monitor other physiological responses, depending on research interest. A wireless network system is appropriate for this application because radio telemetry allows the measurement of biological signals from free-moving conscious animals without direct human contact (Gacsalyi et al., 2000).

Wireless communication and telemetric systems are feasible for on-line data collection tasks and animal monitoring (Kettlewell et al., 1997; West and Merrick, 1966). Wireless networks of sensors greatly extend our ability to monitor and control the physical environment from remote locations (Geers et al., 1998). Such networks improve the accuracy of information obtained from the collaboration among sensor nodes and online information processing at those nodes (Min et al., 2002). Wireless sensor networks using distributed processing can improve the accuracy of vast quantities of sensing information (Asada et al., 2000). Using a sensor network, data can be aggregated to provide a rich, multi-dimensional view of the system monitored. The ability of a sensor network to function accurately when an individual sensor fails is an important attribute. There are, however, several obstacles that must be overcome before a general purpose sensor network can be developed. These obstacles arise from the limited energy, computational power, and communication resources available to the sensors in the network. Using a sensor network in a wireless environment can use up the limited supply of energy simply by performing computations and transmitting information (Min et al., 2002); therefore, energy-conserving forms of communication and computation are essential (Meng and Volkn, 1999).

In this paper, we present the Floating Base Sensor Network (FBSN) protocol, a family of full-connected sensors with a main base radio station via a wireless RF device. The FBSN protocol was used to control EEG signal acquisition and transmission from free moving bovines. The results show that the new protocol presented in this work is able to control telemetric data collection tasks from EEG amplifiers disposed in bovines.

2. Basic equipment architecture

The system consists of two main modules: the first one is responsible for the amplification and transmission of acquired data, and the second receives data and connects the system to a computer.

Fig. 1. Photograph of animal module equipment.

2.1. Animal module

This module (Fig. 1) is positioned on the animal and consists of three main parts: (1) signal amplification and conditioning; (2) digital conversion and system of microprocessor digital communication control; (3) transmission of the digital data. This module has an I2C interface that can be connected to the different digital sensor instruments. The number of devices that can be connected in to the equipment is limited by the total capacitance between the lines SCL and SDA of the I2C interface. This capacitance is limited to 400 pF.

2.1.1. Amplification and conditioning of the signal

The basic architecture of the signal amplification and conditioning module is depicted in Fig. 2. The electronic circuit was constructed using an instrumentation amplifier with

Fig. 2. Block diagram of EEG signal amplification module.

four entrances to operational amplifiers. The circuit was designed to preamplify the signal, filter the signal using both a high-pass and a low pass filter, and then postamplify the signal to ensure a clean signal of sufficient strength. The signal used to test the system was an electroencephalogram signal from free ranging cows. In this case, a preamplification gain of 1000, a high-pass active filter of 0.05 Hz, a low-pass filter of 1.5 kHz, and finally a postamplification gain of 100 were applied.

2.1.2. Digital conversion and control of microprocessor

After amplification and filtering the digital signal was then generated using a 10-bit analog to digital converter. A microprocessor controls signal-sampling frequency. The microprocessor used was 12F675 (Datasheet, 2003), with 4 in/out ports and 15 basic instructions. It operates at 4 MHz, realizing an instruction at each 4-clock cycle. The data acquisition software was developed using machine language and was recorded using the Microchip® (Microchip Technology Inc., Chandler, AZ 85224-6199, USA) development program. Microprocessor program controls signal sampling and transmission was by means of a RS232 interface. Communication protocol was accomplished using a 12F675 microprocessor (Datasheet, 2003) and in-house developed software controlled sending and receiving data from the animal module.

2.1.3. Data transmission

The telemetric system has low energy consumption and high receiving capability. The chosen transceiver was a BIM2-433-160 (Datasheet, 2004). It is bi-directional and data can be transmitted up to 200 m. This transceiver was selected based on its lower power consumption (20 mA at 3.0 V), its compactness and its ability to transmit data at 64 kbps.

The transceiver was connected to the microprocessor to manage digital communications using the RS232 protocol. The wireless network communication protocol was the Floating Base Sensor Network, described in Section 4.

2.2. Base module

The base module is responsible for receiving and storing data from animal modules. It consists of one 433 MHz channel that uses a BIM2 transceiver (BIM2-433-160 by Radiometrix®, 231 Kenton Lane, HA3 8RP Middlesex, UK). To be compatible with the FBSN communication protocol, the base module was designed to receive and store data from a maximum of 100 animal modules for EEG signal acquisition without information loss. This number however is dependent on the physiological measure desired. The software was designed to communicate with the base module, generate a graphical view of the signal and store data.

3. The FBSN protocol

The main objective in implementing this protocol was to allow fast communication without information loss in animal experimentation. The base module sends information to some animal modules requesting stored data. All animal modules receive the base request,

since they are up to 200 m from the base module. When base receives data, this process ends, but if no data has reached the base, it chooses a new base module inside the animal module group in random order. This new base sends information to all animal modules and if a module answer is requested, the new base collects data and then transmits it to the original base module. This process repeats until a maximal interval of data receiving is reached.

The algorithm of FBSN protocol can be described as follows:

Step 0—Until all node information is received.

Step 1—Base station requests data information for a specific node.

Step 2—If a node answers.

Step 2.1—Base station establishes a direct communication to node and gets the data.

Step 2.2—Return to Step 0.

Otherwise

Step 3—Until base station obtains node answer.

Step 3.1—Base station randomly chooses a node to be a floating base.

Step 3.2—The new floating base repeats the base station request to the node.

Step 3.3—If the node answers then:

Step 3.3.1—The floating base establishes direct communication to node get the data requested and send it to base station.

Step 3.3.2—Return to Step 0.

Otherwise return to Step 3.

3.1. Energy consumption

The power consumption characteristics of the FBSN node are considered in three parts: the EEG amplifier circuitry, the digital processing, and the radio transceiver. The circuitry, which consists of the EEG amplifier and the analogical-to-digital converter, requires energy for bias currents, as well as amplification and analog filtering. The power dissipation is relatively constant while on, and improvements to energy efficiency depend on increasing integration and skilled analog circuit design.

In Module 2 (animal module), digital processing circuits are used to perform signal processing of gathered data and implementation of the communication protocol. Energy consumed by digital circuits consists of static and dynamic dissipation. Leakage current (I_l) from power to ground at all times causes static dissipation and can be described by (Min et al., 2002).

$$I_l = I_0 e^{\frac{V_{DD}}{nV_{th}}} \quad (1)$$

where V_{th} is the threshold voltage of the transistors, V_{DD} the supply voltage, and I_0 and n are the constants for the process technology. Dynamic energy is the energy required to energize (“switch”) parasitic capacitors on an integrated circuit from zero voltage (a digital zero) to V_{DD} voltage (or digital one) and is described by:

$$D_{\text{energy}} = CV_{DD}^2 \quad (2)$$

with C representing the switched capacitance. Summing Eq. (1) with Eq. (2), energy yields:

$$E = (tV_{DD})I_0e^{\frac{V_{DD}}{nV_{th}}} + CV_{DD}^2 \quad (3)$$

which is the energy for a computation that switches a total capacitance C over duration t . Eq. (3) indicates that switching energy for any given computation is independent of time, while leakage energy is linear with time. The equipment reduces leakage by setting the power supply to idle components.

The energy consumption of the radio consists of static power dissipated by the analog electronics and the radiated RF energy. The energy W required for a complete radio transmission can be described as

$$W = W_{tx}(t_{trans} + t_{start}) + W_{out}t_{on} \quad (4)$$

where W_{tx} is the power of the transmitter electronics, t_{trans} the transmit duration, t_{start} the startup time, and $W_{out}t_{on}$ is the radiated energy. Most radio transceivers require an initial startup time on the order of hundreds of microseconds, during which transients in the analog electronic need to settle. The system presented in this paper uses a Radiometrix[®] transceiver that has a reasonable cost per bit transmitted and has a measured startup transient of 423 μ s.

4. Wireless network structures

The EEG signal was chosen because there were many difficulties in dealing with this kind of signal. The EEG is very sensitive to electromagnetic interference and the brain electrical activities is on the order of a thousands times smaller (in range of 10^{-6} V) than other sensor electrical responses (in range of 10^{-3} V).

For the purpose of this work, experiments were conducted with an interactive group of six cows positioned in a limited experimental area (50 m $\times$ 100 m). Since cattle do not move in groups most of time, the FBSN can be used to solve the problem of collecting data in areas that are bigger than the transmitter range (BIM2 can transmit data up to 200 m external and 50 m with barriers). A single base module was used to communicate with all the animal modules. The FBSN was designed to communicate with all experimental modules without information loss, using minimum microprocessor program memory space. It is a distributed medium access control protocol that provides robustness against single node failure and support for flexible topologies, in which nodes are partially connected and not all nodes need to have a direct communication with a master. Fig. 3 shows the schematic of FBSN protocol applied in this experiment.

5. Results and discussion

Fig. 4 shows the EEG signal acquired. The quality of the EEG data depends on several conditions, such as electrode positioning and the animal's behavior. For example, when the animal makes a brusque movement (e.g. to scratch the ear), spikes are added to the EEG signal. Despite these spontaneous spikes added to the EEG signal, 98% of signals are free of

Fig. 3. Schematic idea of FBSN protocol. All nodes were listening for base request but only node 3 answer because base was looking for node 3. If node 3 not answer then floating base is turned on.

spurious external artifacts. The EEG power spectral density chart (Fig. 5) shows frequency ranges that correspond to the results of Suzuki et al. (1990).

Routing protocols based on minimum-energy routing and other algorithms have been proposed in the literature (Meng and Volkn, 1999; Kulik et al., 2002). Such protocols use a methodology where observed data from the farthest corners of the network propagate from node to node in a series of predictable short wireless hops, eventually reaching the base station. In the FBSN protocol random choice of wireless communication dictates that only small hops will be used consuming less transmission energy instead of many predictable short wireless links.

FBSN protocol uses a floating base approach to overcome several inefficiencies in traditional telemetric data acquisitions. Direct wireless communication between all network nodes and a potentially distance base station is infeasible. Direct communication would squander precious wireless bandwidth, since frequency reuse would not be possible. In FBSN protocol intermediate nodes act as routers for others' data, performing a kind of multihop routing. In traditional multihop scheme, all data destined for the base station

Fig. 4. EEG signal obtained telemetrically from a free moving bovine.

Fig. 5. Power spectral density of EEG signal acquired.

will flow through the nodes nearest to the base station, causing these nodes to die quickly. Although the FBSN protocol randomly chooses a floating base, all data destined to the radio base will not flow through to all nodes but will be randomly distributed among all possible floating base nodes nearest to the radio base station. The probability of a node to be chosen for a floating base depends on a number of nodes in the network; therefore, the energy consumption of each network node will also be dependent of a node number. The developed prototype with six nodes (animal module) was able to operate for 160 h using two 9 V lithium batteries.

6. Conclusions

This paper describes how the FBSN was introduced, and an application example was used in bovine EEG data acquisition. The examination of FBSN protocol was made both qualitatively and quantitatively. Qualitatively, the FBSN protocol is a feasible solution to data collection in a large sensor network that can be used to monitor physiological responses to livestock. Quantitatively, the application example in the EEG signal shows that the signal acquired from the prototype has acceptable strength and clarity. The next phase of this project will be to test the FBSN protocol with a larger number of animals as well as with other physiological measurements. Our objective is to develop more sophisticated FBSN resources so that available energy can be used efficiently.

Future protocols will make adaptive decisions based not only on the cost of communication data but also on the cost of synthesizing data. Such approaches may be the key to making computation-intensive sensor applications a reality in animal experimentation and monitoring.

Acknowledgements

This work is supported by the FAPESP under the grant number 03/04591-1, and the authors would like to thank PCAPS animal donation and Dr. Fernando C. for and veterinary assistance.

References

- Asada, G., Bhatti, I., Lin, T.H., Natkunathan, S., Newberg, F., Rofougaran, R., Sipos, A., Valoff, S., Pottie, G.J., Kaiser, W.J., 2000. Wireless Integrated Network Sensors (WINS). *Proc. SPIE* 3673, 11–18.
- Brown-Brandl, T.M., Nienaber, J.A., Eingenberg, R.A., Hahn, G.L., Freetly, H., 2003. Thermoregulatory responses of feeder cattle. *J. Therm. Biol.* 28, 149–157.
- Datasheet, 2003. PIC12F629/675 microcontroller family product information. Microchip Data Sheet DSA11906.
- Datasheet, 2004. Low power UHF data transceiver module. Radiometrix BIM Data Sheet Issue 3.
- Gacsalyi, U., Zabielski, R., Pierzynowski, S.G., 2000. Telemetry facilitates long-term recording of gastrointestinal myoelectrical activity in pigs. *Exp. Physiol.* 85 (2), 239–241.
- Geers, R., Saatkamp, H.W., Goossens, K., Van Camp, B., Gorssen, J., Rombouts, G., Vanthemsche, P., 1998. TETRAD: an on-line telematic surveillance system for animal transports. *Comp. Electron. Agric.* 21, 107–116.
- Hahn, G.L., 1999a. Dynamic responses of cattle to thermal heat loads. *J. Anim. Sci.* 77 (Suppl. 2), 10–20.
- Hahn, G.L., 1999b. Dynamic responses of cattle to thermal heat loads. *J. Dairy Sci.* 82 (Suppl. 2), 10–20.
- Kettlewell, P.J., Mitchell, M.A., Meeks, I.R., 1997. An implantable radiotelemetry system for remote monitoring of heart rate and deep body temperature in poultry. *Comp. Electron. Agric.* 17, 161–175.
- Kulik, J., Heinzelman, W., Balakrishnan, H., 2002. Negotiation-based protocols for disseminating information in wireless sensor networks. *Wirel. Netw.* 8 (2-3), 169–185.
- Mader, T.L., Holt, S.M., Hahn, G.L., Davis, M.S., Spiers, D.E., 2002. Feeding strategies for managing heat load in feedlot cattle. *J. Anim. Sci.* 80, 2373–2382.
- Meng, T., Volkn, R., Distributed network protocols for wireless communication, 1999. *Proceedings of the Annual International Conference on Mobile Computing and Networking, MOBICOM*, pp. 174–185.
- Min, R., Bhardwaj, M., Cho, S.H., Ickes, N., Shih, E., Sinha, A., Wang, Chandrakasan, A., 2002. Energy-centric enabling technologies for wireless sensor networks. *IEEE Wirel. Communications* 9 (4), 28–37.
- Sinha, R.K., 2004. Electro-encephalogram disturbances in different sleep-wake estates following exposure to high environmental heat. *Med. Biol. Eng. Comput.* 42, 282–287.
- Sinha, R.K., 2003. Artificial neural network detects changes in electro-encephalogram power spectrum of different sleep-wake estates in an animal model of heat. *Med. Biol. Eng. Comput.* 41, 595–600.
- Suzuki, M., Sitizyo, K., Takeuchi, T., Saito, T., 1990. Electroencephalogram of Japanese black calves affected with cerebrocortical necrosis. *Jpn. J. Vet. Sci.* 52 (5), 1077–1087.
- West, J.K., Merrick, A.W., 1966. A three channel EEG telemetry system for large animals. *Med. Biol. Eng.* 4, 273–281.