

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
INSTITUTO DE INFORMÁTICA  
CURSO DE CIÊNCIA DA COMPUTAÇÃO

BRUNO ALLGAYER FEROLETO

**Um Algoritmo de Médias Móveis para  
Interpretação de Sequências Depositionais  
em uma Arquitetura para Interpretação  
Semântica de Imagens**

Trabalho de Graduação.

Prof. Dr<sup>a</sup>. Mara Abel  
Orientador

Msc. Sandro Rama Fiorini  
Co-orientador

Porto Alegre, Dezembro de 2010.

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos Alexandre Netto

Vice-Reitor: Prof. Rui Vicente Oppermann

Pró-Reitora de Graduação: Profa. Valquiria Link Bassani

Diretor do Instituto de Informática: Prof. Flávio Rech Wagner

Coordenador do CIC: Prof. João César Netto

Bibliotecária-Chefe do Instituto de Informática: Beatriz Regina Bastos Haro

# SUMÁRIO

<b>LISTA DE ABREVIATURAS E SIGLAS.....</b>	<b>5</b>
<b>LISTA DE FIGURAS.....</b>	<b>6</b>
<b>LISTA DE TABELAS.....</b>	<b>8</b>
<b>RESUMO.....</b>	<b>9</b>
<b>1 INTRODUÇÃO.....</b>	<b>11</b>
1.1 Motivação .....	11
1.2 Objetivos.....	12
1.3 Organização dos Capítulos.....	12
<b>2 INTERPRETAÇÃO SEMÂNTICA DE IMAGENS.....</b>	<b>13</b>
2.1 Agregados.....	15
2.1.1 Evoluções da Abordagem dos Agregados.....	17
2.2 Abdução.....	18
2.2.1 Evoluções da Abordagem Abdutiva.....	20
2.3 Orion.....	21
2.3.1 Evoluções da abordagem Orion.....	24
2.4 Espaços Conceituais.....	24
2.4.1 Evoluções da Abordagem dos Espaços Conceituais.....	29
2.5 Comparativo Entre as Abordagens.....	29
<b>3 O FRAMEWORK S-CHART E O SISTEMA INTELISTRATA.....</b>	<b>32</b>
3.1 Framework S-Chart.....	32
3.2 Sistema Intelistrata.....	34
3.3 Estratigrafia de Sequências.....	35
<b>4 UM NOVO ALGORITMO.....</b>	<b>38</b>
4.1 O novo algoritmo.....	38
4.1.1 Curva de Tendências.....	40
4.1.2 Limites de Sequências Deposicionais.....	43

<b>5 VALIDAÇÃO DA PROPOSTA.....</b>	<b>48</b>
5.1 Comparativo de resultados: Novo algoritmo x Intelistrata.....	48
5.2 Testes em novos perfis de poços.....	54
<b>6 CONCLUSÃO.....</b>	<b>59</b>
6.1 Trabalhos Futuros.....	59
<b>REFERÊNCIAS.....</b>	<b>60</b>

## **LISTA DE ABREVIATURAS E SIGLAS**

- DL Description Logics (Lógica de descrição)
- GSD Geometrical Scene Description
- GUI Graphical User Interface
- LDA Linear Discriminant Analysis (Discriminante Linear)
- OWL Web Ontology Language

## LISTA DE FIGURAS

<b>FIGURA 2.1: EXEMPLO DE INTERPRETAÇÃO DE ANCORAMENTO SIMBÓLICO (FIORINI, S. R., 2009).....</b>	<b>14</b>
<b>FIGURA 2.2 – FRAMEWORK BASEADO EM CONHECIMENTO PARA INTERPRETAÇÃO DE ALTO NÍVEL DE CENAS (NEUMANN, B. E R. MÖLLER, 2006) .....</b>	<b>16</b>
<b>FIGURA 2.3: ROBÔ LUDWIG (SHANAHAN, M. E D. A. RANDELL, 2004) .....</b>	<b>19</b>
<b>FIGURA 2.4: BLOCOS LEGO E SUAS ARESTAS (SHANAHAN, M. E D. A. RANDELL, 2004).....</b>	<b>20</b>
<b>FIGURA 2.5: OS 3 NÍVEIS DE ABSTRAÇÃO CORRESPONDENTES AOS SUB-PROBLEMAS REPRESENTADOS ATRAVÉS DE UMA IMAGEM MICROSCÓPICA DA BIOLOGIA (HUDELOT, C. ET AL., 2004).....</b>	<b>21</b>
<b>FIGURA 2.6: ANCORAMENTO SIMBÓLICO: 3 NÍVEIS E ONTOLOGIAS PARA COMUNICAÇÃO (HUDELOT, C. ET AL., 2004).....</b>	<b>23</b>
<b>FIGURA 2.7: EXEMPLO DE ANCORAMENTO SIMBÓLICO CONSTRUÍDO A PRIORI (HUDELOT, C. ET AL., 2004).....</b>	<b>24</b>
<b>FIGURA 2.8: A ARQUITETURA PROPOSTA PELA ABORDAGEM DOS ESPAÇOS CONCEITUAIS E SEUS 3 DIFERENTES NÍVEIS (CHELLA, A. ET AL., 1997).....</b>	<b>25</b>
<b>FIGURA 2.9: UMA IMAGEM COM SEUS OBJETOS TRANSFORMADOS EM KNOXELS (CHELLA, A. ET AL., 1997).....</b>	<b>26</b>
<b>FIGURA 2.10: VARIAÇÃO DOS FATORES DE FORMA (CHELLA, A. ET AL., 2001).....</b>	<b>27</b>

<b>FIGURA 2.11: FRAGMENTO DE CONHECIMENTO NO COMPONENTE TERMINOLÓGICO (CHELLA, A. ET AL., 1997).....</b>	<b>28</b>
<b>FIGURA 2.12: SITUAÇÃO NO COMPONENTE TERMINOLÓGICO (CHELLA, A. ET AL., 1997) .....</b>	<b>28</b>
<b>FIGURA 2.13: MARTELO REPRESENTADO POR SEUS KNOXELS EM UM ESPAÇO CONCEITUAL (CHELLA, A. ET AL., 2001).....</b>	<b>29</b>
<b>FIGURA 3.1: ARQUITETURA DO FRAMEWORK S-CHART (FIORINI, S. R., 2009).....</b>	<b>33</b>
<b>FIGURA 3.2: ARQUITETURA DO COMPONENTE DE INTERPRETAÇÃO (FIORINI, S. R., 2009).....</b>	<b>34</b>
<b>FIGURA 3.3: ARQUITETURA DO SISTEMA INTELISTRATA (FIORINI, S. R., 2009).....</b>	<b>34</b>
<b>FIGURA 3.4: EXEMPLO DE PERFIL DE RAIOS GAMA. EDITADO DE (FIORINI, S. R., 2009).....</b>	<b>37</b>
<b>FIGURA 4.1: WAVELET GAUSSIANA 2 (FIORINI, S. R., 2009).....</b>	<b>39</b>
<b>FIGURA 4.2: EXEMPLO DE CURVA DENTE-DE-SERRA .....</b>	<b>39</b>
<b>FIGURA 4.3: CURVA DE TENDÊNCIAS.....</b>	<b>42</b>
<b>FIGURA 4.4: “FALHA” DEVIDO A UMA QUEDA BRUSCA.....</b>	<b>44</b>
<b>FIGURA 4.5: QUEDAS BRUSCAS EM REGIÕES COM DIFERENTES AMPLITUDES DO VALOR GAMA.....</b>	<b>45</b>
<b>FIGURA 5.1: COMPARAÇÃO DAS INTERPRETAÇÕES DO ESPECIALISTA E DO SISTEMA INTELISTRATA PARA O PERFIL DE POÇO TENNECO RATTLESNAKE STATE 2-12 (FIORINI, S. R., 2009).....</b>	<b>50</b>
<b>FIGURA 5.2: INTERPRETAÇÃO DO PERFIL DE POÇO TENNECO RATTLESNAKE STATE 2-12 PELO NOVO ALGORITMO.....</b>	<b>51</b>
<b>FIGURA 5.3: COMPARAÇÃO DAS INTERPRETAÇÕES DO ESPECIALISTA E SISTEMA INTELISTRATA PARA O PERFIL DE POÇO EXXON PRODUCTION RESEARCH CO. SEGO CANYON Nº 2 (FIORINI, S. R., 2009).....</b>	<b>52</b>

<b>FIGURA 5.4: INTERPRETAÇÃO DO PERFIL DE POÇO EXXON PRODUCTION RESEARCH CO. SEGO CANYON Nº 2 PELO NOVO ALGORITMO.....</b>	<b>53</b>
<b>FIGURA 5.5: INTERPRETAÇÃO DO PERFIL DE POÇO CA-53 PELO NOVO ALGORITMO.....</b>	<b>56</b>
<b>FIGURA 5.6: INTERPRETAÇÃO DO PERFIL DE POÇO CA-79 PELO NOVO ALGORITMO.....</b>	<b>57</b>
<b>FIGURA 5.7: INTERPRETAÇÃO DO PERFIL DE POÇO CA-87 PELO NOVO ALGORITMO.....</b>	<b>58</b>

## **LISTA DE TABELAS**

<b>TABELA 2.1: COMPARAÇÃO ENTRE ABORDAGENS SEMÂNTICAS DE RECONHECIMENTO DE OBJETOS.....</b>	<b>31</b>
<b>TABELA 5.1: RESULTADOS DO NOVO ALGORITMO.....</b>	<b>54</b>

## RESUMO

A interpretação semântica de imagens é atualmente uma das áreas mais exploradas da computação. Ao longo dos anos tentou-se descobrir a melhor forma de entender e reproduzir o processo cognitivo humano. Atualmente um dos pontos que mais chamam atenção é como extrair o real significado de uma imagem e suas associações. Uma das áreas que tem necessidade direta desse conhecimento é a área da geologia chamada Estratigrafia e sua metodologia, Estratigrafia de Sequências, uma das mais novas e eficientes ferramentas cuja correta interpretação dos resultados permite uma boa predição da formação dos sistemas deposicionais que orienta a exploração de petróleo.

Dentro da área de interpretação semântica de imagens há diferentes trabalhos que apresentam suas arquiteturas e soluções para problemas específicos. Voltado à estratigrafia de sequências há o sistema Intelistrata, arquitetado a partir do framework S-Chart. Neste trabalho é apresentado um novo algoritmo para o componente de processamento do sinal, tendo como objetivo uma melhor interpretação das imagens.

Para alcançar os objetivos foram utilizadas noções matemáticas de médias móveis e desvio padrão, visando identificar certos aspectos interessantes para a delimitação de limites de sequências deposicionais utilizando perfis de raios gama. A abordagem provê aos componentes de interpretação semântica de imagens do sistema Intelistrata dados mais precisos e, conseqüentemente, melhores resultados.

O novo algoritmo utilizado mostrou ganhos substanciais em relação à aplicação original ao identificar automaticamente limites de sequências deposicionais em poços exploratórios utilizados para teste. Os ganhos foram tanto em qualidade quanto eficiência nas demarcações de limites de sequência deposicionais. Contando com duas comparações feitas em relação ao sistema original houve acerto de 100%, contra 66% em relação às demarcações de limites de sequências deposicionais e eficiência de 75% na quantidade de marcações feitas contra 40% e 50% do sistema original. Ainda teve boa aproximação de marcações em outros perfis de poços, nas quais seus erros quando não houve marcação precisa em relação à interpretação feita manualmente por um geólogo, não ultrapassaram 4% do tamanho dos poços. As maiores discrepâncias aconteceram em poços onde mesmo especialistas tiveram dificuldade em fazer tais marcações somente com a informação do perfil de raios gama, o que aumenta a credibilidade do novo algoritmo e prova seu valor como ferramenta de auxílio aos especialistas da área.

**Palavras-Chave:** Interpretação Semântica de Imagens, Visão Computacional, Processamento de Sinal, Estratigrafia de Sequências.



# 1 INTRODUÇÃO

Este trabalho aborda a área da ciência da computação chamada “visão computacional”, discutida mais amplamente pela primeira vez em (Ballard, D. H. e C. M. Brown, 1982), para o estudo da extração de dados de imagens, esses por sua vez podendo ser processados posteriormente, tanto por humanos quanto máquinas, buscando cumprir alguma tarefa. A interpretação semântica de imagens é a área da Inteligência Artificial derivada da visão computacional, que busca algo mais além da simples extração numérica de conteúdos das imagens sem significados semânticos. Seu ideal é dar significado aos dados extraídos das imagens, muitas vezes tentando simular o que seria o comportamento humano.

Este trabalho visa o estudo das abordagens de interpretação semântica de imagens, aplicada a interpretação de sequências deposicionais. A Estratigrafia de Sequências, apresentada inicialmente por Vail et al. (1977), posteriormente refinada por Posamentier et al. (1988) e Van Wagoner et al. (1990), como apontado por Catuneanu (2006), é uma área de estudos recentes da Geologia responsável pelo estudo da formação dos estratos do subsolo pela variação do nível do mar e deposição de matéria orgânica. Sua correta interpretação permite uma boa predição da formação dos sistemas deposicionais que orienta a exploração de petróleo.

## 1.1 Motivação

Relativamente nova, a área da visão computacional ainda tem muito a ser explorada, considerando que nem mesmo possui uma formalização padrão, mas sim diversos estudos aplicados a problemas distintos. Essa também é uma área muito promissora pela grande ajuda que pode nos dar ao resolver problemas tanto de altos graus de dificuldades, como, por exemplo, diagnósticos médicos e outros tipos de interpretação, ou mesmo problemas que exigiriam alta demanda de trabalho, como, por exemplo, catalogar todos os gols que um jogador fez ao longo da carreira.

A área de estratigrafia de sequências, também relativamente nova, oferece fortes ferramentas para a análise estratigráfica cujo estilo vem sendo tomado como o preferido pelos geólogos ao longo dos últimos anos (CATUNEANU, O., 2006). Unindo-a com a área da visão computacional e interpretação semântica de imagens é possível criar ferramentas muito efetivas e úteis no momento em que nosso país torna-se um dos mais fortes na exploração de petróleo, contando com pesado investimento, sendo mais de 70 bilhões de reais investidos em 2009 no aumento da capacidade de produção de petróleo e gás natural, dos quais mais de 30 bilhões de reais em exploração e produção e 2,8 bilhões de dólares investidos para o período até 2013, segundo (PETR).

Com diversos trabalhos na área de interpretação semântica de imagens, tendo algumas boas abordagens, apresentadas no segundo capítulo, poucos trabalhos buscam a área de estratigrafia de sequências, deixando o caminho livre para inovações, como o *framework* apresentado por Fiorini (2009), ou os resultados conseguidos pela abordagem semelhante de Xia (2009).

Criado a partir das linguagens OWL e Java, o *framework* S-Chart tem como foco a interpretação semântica de gráficos através da combinação de algoritmos de processamento de sinais com algoritmos e modelos de raciocínio simbólico. Divide-se em 3 níveis: semântico, visual e analógico, sendo os dois primeiros destinados às interpretações e o último ao processamento de imagens. Sua aplicação, o sistema Intelistrata, busca a utilização de suas ferramentas para inferências no âmbito da estratigrafia de sequências, como delimitação de sequências deposicionais e parassequências.

## 1.2 Objetivos

O objetivo deste trabalho é propor um novo algoritmo de processamento de sinal para o sistema Intelistrata, desenvolvido por Fiorini (2009), buscando maior precisão do algoritmo de identificação dos limites de sequências deposicionais em depósitos sedimentares siliciclásticos em bacias sedimentares do tipo Margem Passiva. Para tal será utilizada uma nova abordagem para o algoritmo, utilizando-se médias móveis, ao invés das *wavelets* utilizadas no sistema original. Dessa forma espera-se, em trabalhos futuros, estender as funcionalidades do sistema Intelistrata, utilizando-se a base para inferências e também uma arquitetura já definidas e própria para expansões do *framework* S-Chart.

## 1.3 Organização dos Capítulos

O capítulo 2 revisa conceitos e trabalhos relacionados à área da visão computacional, apresentando algumas das principais abordagens, apontando seus pontos fortes e fracos e terminando por compará-las.

O capítulo 3 introduz o *framework* S-Chart e sua aplicação, o sistema Intelistrata, voltado para a estratigrafia de sequências, sendo essa última abordada em maiores detalhes ao fim do capítulo.

O capítulo 4 apresenta a proposta de um novo algoritmo ao sistema, buscando melhores resultados.

O capítulo 5 mostra a validação e os resultados alcançados pelo novo algoritmo apresentado no capítulo anterior.

O sexto e último capítulo apresenta as conclusões do trabalho, comentando seus resultados e possíveis avanços futuros.

## 2 INTERPRETAÇÃO SEMÂNTICA DE IMAGENS

O principal desafio dos sistemas de visão computacional é interpretar corretamente o conteúdo de imagens. Um sistema desse tipo deve ter como saída uma descrição, formal ou não, dos objetos presentes em uma imagem, bem como a sua classificação e suas propriedades visuais. (FIORINI, S. R., 2009, p.21)

Um sistema de visão computacional consiste em saber dar o correto significado ao que vemos, ou, no caso, ao que o sistema “vê”. Assim foram criadas diversas tentativas de chegar a uma solução, desde algoritmos simples de extração de feições de imagens, como retas, superfícies, regiões e texturas, até a tentativa de simulação do conhecimento de um especialista humano. A limitação é que até hoje o processo cognitivo humano não é completamente conhecido para que possa ser transformado em um algoritmo e então simulado. Até o momento, a interpretação semântica de imagens é um problema que persiste sem uma solução completa.

Com os diversos estudos na área, chegou-se à conclusão de que o significado de um objeto em uma imagem não está no seu formato, nome, ou taxonomia. Só sabemos dar um significado, por exemplo, ao termo, ou ao objeto chamado “carro” por vivência e por encontrá-lo contextualizado de certa forma em alguma cena, mas esse símbolo por si só nada nos diz a respeito de seu significado. Indo além, o termo “carro” é uma palavra da língua portuguesa e fica ainda mais óbvio pelo fato de que ele nada significa a alguém que nunca tenha tido contato com essa língua. Essa falta de significado intrínseco ao termo, ou no caso de uma imagem, um objeto nela reconhecido, traz a necessidade de uma atribuição do valor semântico (o significado) a um objeto da imagem (o símbolo).

A associação de um símbolo com o objeto ao qual ele se refere é referenciado na literatura como o problema do ancoramento simbólico (*the symbol grounding problem*) e visa responder, segundo Harnad, S. (1990, p.1):

Como a interpretação semântica de um sistema simbólico formal pode ser intrínseca ao sistema, ao invés de apenas parasítico como em nossas mentes? Como podem os significados de símbolos sem significado, manipulados exclusivamente em função de suas formas (arbitrárias), serem ancorados a algo que não outros símbolos sem significado?

Esse questionamento vem da tentativa de dar um real significado a cada símbolo ao invés de simplesmente tentar relacioná-lo a outros. Dentre as capacidades humanas, aquelas que são procuradas para a solução do ancoramento simbólico são: discriminação, manipulação, identificação e capacidade de produzir e responder descrições de objetos ou eventos. Os sistemas que delas se utilizam, ancoram os valores semânticos às feições encontradas na imagem, referentes a um símbolo. Esse ancoramento pode ter tanto uma abordagem *top-down*, na qual a partir de um conjunto

de valores semânticos são procuradas feições na imagem, quanto *bottom-up*, cujo processamento de imagem extrai todas as feições possíveis e tenta conectá-las a valores semânticos. Há uma espécie de consenso que considera os valores semânticos como alto nível e a imagem e suas feições, ou símbolos, como baixo nível.

Geralmente os sistemas costumam fazer uma abordagem híbrida e iterativa na tentativa de melhores resultados. Como o exemplo de Fiorini, S. R. (2009), caso fosse utilizado um sistema de interpretação de imagens de satélite, uma imagem teria regiões extraídas na Figura 2.1a. A partir de uma abordagem *bottom-up*, essas regiões seriam interpretadas como sendo um rio e uma estrada (Figura 2.1b). Considerando que o modelo simbólico definiria que na sobreposição das entidades “rio” e “estrada” poderia haver uma ponte, o interpretador passaria ao sentido *top-down* em busca de características visuais que confirmassem essa hipótese (Figura 2.1c).

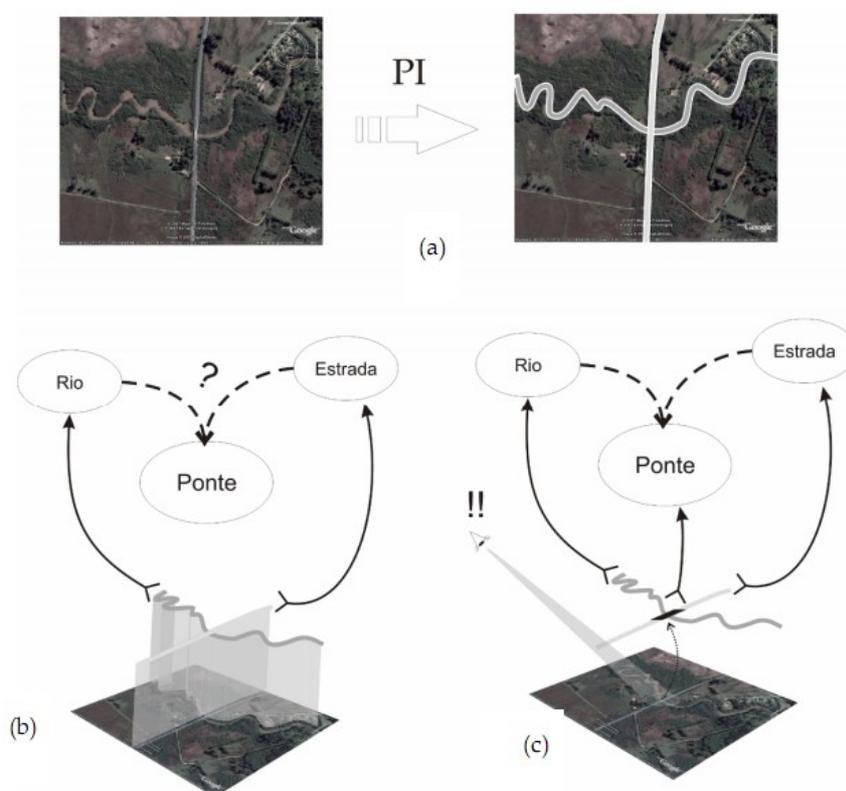


Figura 2.1: Exemplo de interpretação de ancoramento simbólico (FIORINI, S. R., 2009)

Alguns sistemas de visão computacional são divididos em partes chamadas de níveis. Esses níveis são denominados para aumentar a modularidade, diminuir a complexidade dos sistemas e ainda melhorar a clareza do sistema de interpretação semântica. Como dito anteriormente, há um consenso de que os valores semânticos atribuídos à imagem são o “alto nível”, enquanto a imagem bruta e suas possíveis feições são o “baixo nível”. Os níveis podem ainda receber diferentes nomes, como “nível semântico” e “nível da imagem” ou mesmo contar com níveis intermediários, como “nível visual” (HUDELOT, C. et al., 2004), para diminuir a distância e complexidade dos problemas entre níveis, dividindo-os em sub-problemas, podendo assim conter algumas propriedades da imagem e de cada objeto nela encontrado, mas ainda sem a apropriação de seu valor semântico, seu significado.

Os diferentes níveis possuem diferentes abordagens, focos e linguagens, assim, a partir da sua utilização, é também necessário definir uma maneira de fazer comunicação entre eles. Essa comunicação pode ser feita de diversas maneiras, como a criação de ontologias visando uma linguagem comum, ou simplesmente dados vindos de um nível para posterior processamento no nível que os recebe. Por exemplo, regiões de uma imagem que de acordo com seu formato e cor podem receber diferentes valores em um nível intermediário, a exemplo da Figura 2.5 na seção 2.3.

A seguir são apresentadas algumas das principais abordagens que utilizam esses conceitos.

## 2.1 Agregados

O trabalho de (NEUMANN, B. e R. MÖLLER, 2006) visa analisar a possibilidade do uso de Lógica de Descrição (*Description Logics – DL*) como representação de conhecimento e sistema de raciocínio para interpretação de alto nível de cenas. O sistema proposto pelos autores visa a análise de cenas, podendo intuir o que está acontecendo. Foi voltado, inicialmente, à monitoração de tráfego, já que o sistema inclui primitivas de representação de objetos ao longo do tempo.

A abordagem foi proposta tendo em mente os seguintes aspectos:

1. Representação de conhecimento necessita uma forte base formal quando o corpo de conhecimento se torna maior e diverso. Muitas das representações de formalismos anteriores como redes semânticas, linguagens de frames e sistemas baseados em regras sofreram de falta de uma semântica precisa no sentido de que o correto uso de conhecimento representado é parcialmente baseado em noções intuitivas, que não necessariamente proveem uma base consistente para processamento de conhecimento de larga escala.

2. Sistemas de representação de conhecimento podem prover serviços de inferência padronizados que podem ser utilizados (e reutilizados) para desenvolvimento de aplicações. Serviços de inferência típicos são de checagem de consistência, herança, classificação de instâncias e construção de modelos, mas muitos outros foram propostos e investigados, como, por exemplo, *pattern matching* (BAADER, F. e R. KUESTERS, 1999). Serviços de inferência são interessantes para interpretação de cenas já que podem prover importantes funcionalidades para o processo de interpretação em termos de software existente com propriedades bem definidas.

3. Há um crescente corpo de pesquisa com respeito a conhecimento espacial e temporal e sistemas de raciocínio relacionados (VILA, L., 1994) (STOCK, O., 1997) (COHN, A. G. e S. M. HAZARIKA, 2001). Espaço e tempo têm um papel determinante em cenas e pode-se esperar que serviços de raciocínio visual e temporal provenham suporte para interpretação delas. Entretanto, é notável que até agora apenas alguns poucos exemplos dessa integração tenham sido feitos em sistemas de visão (*vision system*) (HAAG, M. et al., 1997) (NAGEL, H.-H., 1999) (COHN, A. G. et al., 2003). Um dos problemas parece ser a incompatibilidade quantitativa entre informações espaciais e temporais vindas de visualizações de baixo-nível e a natureza qualitativa dos seus sistemas de raciocínio.

4. Lógica de Descrição constitui uma família de formalismos de representação de conhecimento que tem recebido muita atenção na última década. Lógica de Descrição oferece representação de conhecimento orientado a objetos similar a linguagens de frames usados em muitos sistemas baseados em conhecimento, mas baseado em semântica formal. A Lógica de

Descrição representa um subconjunto do Cálculo de Predicados de Primeira Ordem, que é geralmente escolhido por sua garantia de decidibilidade de checagem de consistência e outros serviços de inferência chaves. Além do que, recentes desenvolvimentos de sofisticadas técnicas de otimização levaram a sistemas de Lógica de Descrição que combinam uma expressiva representação de linguagem com serviços altamente eficientes. Em (BAADER, F. et al., Eds., 2003) é provido um excelente *overview* do estado da arte da metodologia da Lógica de Descrição. (NEUMANN, B. e R. MÖLLER, 2006, p.2-3)

Ao longo do trabalho, os autores apresentam os termos interpretação de alto nível (*high-level interpretation*) – que levam a estruturas conceituais que podem ser descritas como interpretações – e agregados, o ponto principal da abordagem. O primeiro termo é definido como a tarefa de entender uma cena indo além do simples reconhecimento de objetos. Para tal é proposto o seguinte *framework*:

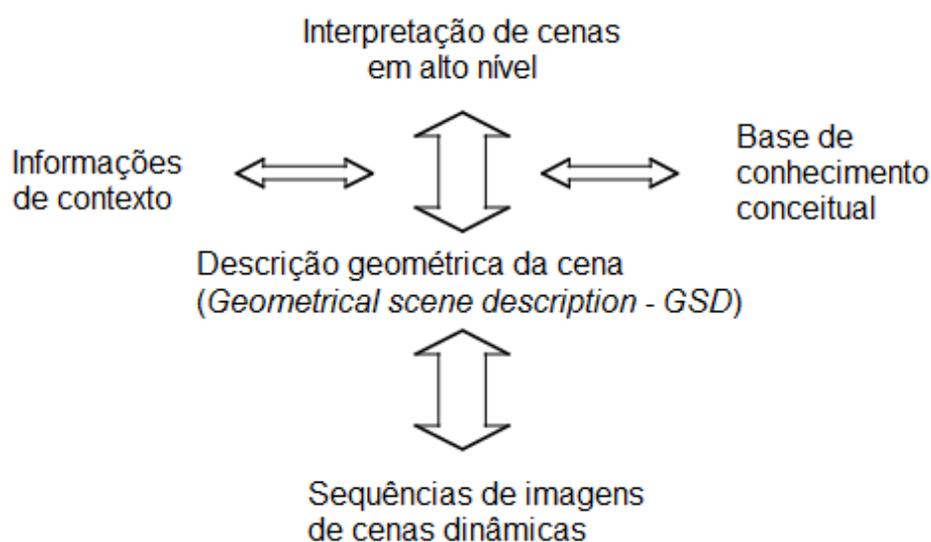


Figura 2.2 – Framework baseado em conhecimento para interpretação de alto nível de cenas (NEUMANN, B. e R. MÖLLER, 2006)

Como bem apontado por Fiorini, S. R. (2009), os autores não especificam claramente como seria a passagem de dados da interpretação de baixo para alto nível. Simplesmente é citado o uso do intermediário GSD (*Geometrical Scene Description*), introduzido pelo próprio autor em (NEUMANN, B., 1989) que, nas palavras dele mesmo, é um conveniente separador entre processos de alto e baixo nível. Logo após ainda é declarado que neste trabalho esses tipos de processos deverão interagir, assim não se assume que o GSD seja completo ou correto em qualquer sentido. Também são deixadas de lado as dificuldades da interpretação de baixo nível das imagens, assumindo-se que uma reconstrução geométrica parcial da cena estará disponível.

Ainda quanto à interpretação de alto-nível, são listadas algumas características esperadas:

- Envolver diversos objetos e ocorrências.
- Dependem das relações temporais e espaciais entre partes de uma cena.
- Descrever cenas em termos qualitativos, omitindo detalhes geométricos.

- Explorar informação contextual.
- Incluir fatos inferidos, não observáveis na cena.
- Baseado em conhecimento visual e experiências sobre o mundo.

O termo “agregados” é descrito como a principal entidade conceitual. Ele consiste em um conjunto de partes unidas para formar um conceito que satisfaz certas restrições. Como exemplos utilizados pelos autores, um agregado pode ser um conjunto de louças e talheres que podem vir a definir se a cena que está sendo vista é de uma mesa de café da manhã, almoço, etc. Segundo os autores a principal motivação para definir um agregado é prover uma descrição coerente de entidades que ocorrem em uma cena, independentemente de estarem ou não, visíveis, podendo haver a inferência de algum elemento que não esteja evidente nela, estando de acordo com as características de uma interpretação de alto nível citada acima.

Ainda quanto às escolhas feitas pelos autores, é defendido o uso de Lógica de Descrição, usando-se o argumento de que, como já visto em diversos sistemas de frames e redes semânticas, não é necessário o uso de uma lógica de primeira ordem, utilizando-se apenas algumas partes dela, tendo uma grande vantagem sobre os provadores de teoremas necessários na lógica completa. Lógica de Descrição também é defendida por ter uma semântica formal que evita ambiguidades que geralmente surgem em sistemas de conhecimento quando construídos intuitivamente.

No decorrer do trabalho de Neumann e Möller (2006), é apontado o uso do sistema *RACER* (HAARSLEV, V. e R. MÖLLER, 2001), que implementa serviços de inferência na Lógica de Descrição  $ALCQHI_{R+}(D^-)$ , também chamada de  $SHIQ(D_n)$ , considerado suficiente, já que, segundo os autores, os requisitos do sistema são satisfeitos com a lógica  $ALCF(D)$ . Entretanto, o que fica latente é o fato de que não há suporte para a escolha de qual agregado será construído primeiro, algo que geraria *backtracking* e ineficiência para a interpretação da cena, já que no momento em que o trabalho foi elaborado esse tipo de suporte estava fora do escopo dos sistemas de Lógica de Descrição da época. Esse tipo de problema não resolvido acaba tirando boa parte da credibilidade do trabalho, já que ele não resolve grande parte daquilo que se propõe, apresentando simplesmente uma solução teórica que apenas funcionaria num mundo que não existe, deixando assim pouco proveito prático.

Por fim, o trabalho não deixa explícito se utiliza uma abordagem *top-down* ou *bottom-up*; contudo, no capítulo 5.2 - *Supporting the Scene Interpretation Process with a DL System*, é apontada a necessidade de *instance merging*, um passo tipicamente utilizado quando uma instância *top-down* hipotética precisa se conectar a uma evidência *bottom-up*. Isso leva a crer uma abordagem híbrida, tendo um processamento *bottom-up* para as imagens no baixo nível e interpretações *top-down*.

### 2.1.1 Evoluções da Abordagem dos Agregados

Dentre as evoluções do trabalho de Neumann e Möller (2006) temos os seguintes artigos:

Em KREUTZMANN, A. et al., (2009), o trabalho estende os antigos trabalhos de Neumann, utilizando um modelo probabilístico de alto nível. Nesse modelo

probabilístico, são utilizadas árvores de decisão e hierarquias de composição bayesianas (*Bayesian Compositional Hierarchies*). O trabalho também visa a evolução da classificação dos objetos utilizando o *framework* SCENIC (HOTZ, L. e B. NEUMANN, 2005). Os autores alegam que esse método reduz a complexidade e melhora a qualidade da interpretação para cenas temporais, também reduzindo a incidência de falsos positivos.

Em (HOTZ, L. et al., 2008) também é utilizado o *framework* SCENIC. Sua principal contribuição é a utilização clara de um nível intermediário para “comunicação” entre o alto e baixo nível, sendo que, suas principais características são o casamento entre evidências do baixo nível com conceitos do alto nível, confirmação ou refutação de hipóteses do alto nível e início de atividades do baixo nível a partir de hipóteses do alto nível. Aqui também fica claro o uso da abordagem *top-down*.

Mesmo sendo duas das mais interessantes evoluções do trabalho, elas não possuem um avanço suficiente para serem tratadas como uma nova abordagem.

## 2.2 Abdução

A abordagem abdução de (SHANAHAN, M. e D. A. RANDELL, 2004) é proposta para uso em robôs, tendo como motivação o fato de que, até o momento de sua publicação, as ações dos robôs eram geradas assumindo-se que a percepção de cenas estava em uma caixa-preta que poderia prover dados sobre o mundo em um alto nível, sem a preocupação de como os dados brutos do baixo nível seriam transformados em dados de alto nível.

Os experimentos no artigo foram realizados com o robô LUDWIG, um humanóide composto por tronco, dois braços, cada um com 3 graus de liberdade e uma *stereo camera* em uma cabeça *pan-and-tilt* (uma cabeça que gira sobre o próprio eixo, simulando a movimentação de uma cabeça humana). A função desse robô é identificar objetos interessantes e então mexê-los utilizando servovisão. Ele cumpre a sua tarefa com ajuda da extensão dada à abdução básica em (SHANAHAN, M., 2002), um *framework* que permite o fluxo bidirecional entre cognição e a imagem de baixo nível, segundo os autores, tendo o potencial de abranger cognição, ação e percepção. Um importante aspecto também é capacidade de melhorar a representação de um objeto através da interação com ele. Dessa forma, é tido como grande contribuição do artigo superar as deficiências de tentativas prévias de caracterização lógica da percepção de robôs utilizando abdução. O trabalho é feito através de um meta-interpretador escrito em prolog com o processamento das imagens no baixo nível feitas em C++, tendo ainda a interação com o usuário, para melhorar a percepção que deseja-se dar ao robô.

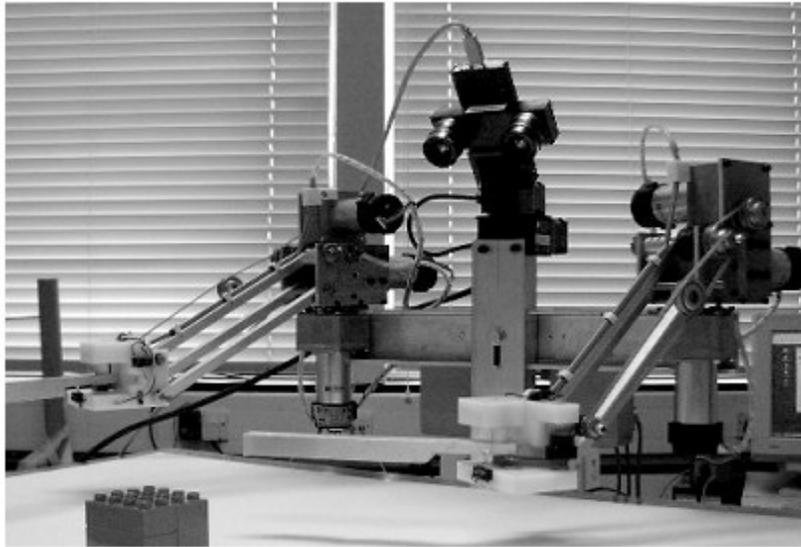


Figura 2.3: Robô LUDWIG (SHANAHAN, M. e D. A. RANDELL, 2004)

A percepção visual dada pela abdução é feita da seguinte forma:

Sendo  $\Sigma$  a teoria que captura a relação causal entre objetos de uma cena ou imagem e os dados retirados dessa imagem de baixo nível,  $\Gamma$  uma conjunção de fórmulas representando uma coleção de dados da imagem no baixo nível, a tarefa é encontrar uma conjunção  $\Delta$  de fórmulas, tal que:

$$\Sigma \wedge \Delta \models \Gamma$$

Dessa forma, a idéia é encontrar hipóteses na cena que expliquem os dados visuais que o robô recebeu. Assim, temos que  $\Delta$  deve ser consistente com  $\Sigma$  e deve conter apenas predicados considerados “abduíveis”, construindo assim diversos  $\Delta$  que explicam  $\Gamma$ , devendo-se utilizar o  $\Delta$  que contenha mais informação e ela deve ser correta.

Temos que:

Sendo  $\Delta_1 \dots \Delta_n$  o conjunto de todas hipóteses que explicam  $\Gamma$ .

Dado que uma e apenas uma dessas hipóteses pode ser a verdadeira explicação, e se nenhuma das hipóteses é absorvida por qualquer outra, podemos assumir  $\Delta_1 \dots \Delta_n$ .

Considerando uma hipótese qualquer  $\Delta_k$  e  $R$  sendo  $\Delta_1 \dots \Delta_{k-1} \Delta_{k+1} \dots \Delta_n$ .

Temos, pelas leis da probabilidade:

$$P(\Delta_k | \Delta_k \quad R) = \left( 1 + \frac{P(R)}{P(\Delta_k)} \right)^{-1}$$

Onde  $P(\Delta_k)$  é a probabilidade prévia de  $\Delta$  e  $P(R)$ , a de  $R$ , temos:

$$P(R) = \left( \sum_n^{i=1} P(\Delta_i) \right) - P(\Delta_k)$$

Para qualquer hipótese  $\Delta$  na forma  $\Psi_1 \wedge \dots \wedge \Psi_m$ , temos:

$$P(\Delta) = \prod_{j=1}^m P(\psi_j)$$

Como exemplo de aplicação é dada a identificação de blocos Lego como pode ser visto na Figura 2.4:



Figura 2.4: Blocos Lego e suas arestas (SHANAHAN, M. e D. A. RANDELL, 2004)

A primeira parte da Figura 2.4 representa a visão do robô, a segunda, a detecção de arestas Sobel, já a terceira, mostra a identificação de cada aresta pelo algoritmo, ou seja, o processamento da imagem no baixo nível. O algoritmo visa primeiramente a abdução de áreas trapezoidais a partir da identificação das arestas e, em um segundo momento, a abdução de cubóides dentro dessas áreas. Esse trabalho é feito utilizando axiomas lógicos de primeira ordem, relacionando às primitivas de baixo nível retas e pontos com as regiões trapezoidais e cubóides. O núcleo do trabalho, o meta-interpretador, trabalha com uma lista de hipóteses ordenadas de acordo com seu poder de explicação de  $\Gamma$ , então suas expectativas são confirmadas, ou não, reordenando assim as hipóteses. Ao fim desse processo, que ainda pode contar com o ajuste do usuário, temos o resultado que é a hipótese que fica melhor posicionada e temos então um trabalho com uma abordagem híbrida (*top-down* e *bottom-up*).

Indo um pouco além da simples abordagem do trabalho há algumas evoluções para melhor resposta em termos de interpretação de cenas, como a percepção ativa, cálculo de eventos, abdução de eventos visuais para respostas do robô contextualizadas através de sensores visuais e não apenas de proximidade e *aspect graphs*, que representam diversas visões de um mesmo objeto, podendo assim facilitar sua identificação.

### 2.2.1 Evoluções da Abordagem Abdutiva

Dentre os trabalhos encontrados até o momento da revisão bibliográfica deste trabalho (Junho de 2010), o único que pode ser encarado como uma evolução na abordagem abdutiva de (SHANAHAN, M. e D. A. RANDELL, 2004) é o encontrado em (RANDELL, D. e M. WITKOWSKI, 2006). Sua principal contribuição é a utilização de *feature clouds*, uma estrutura de dados que codifica características heterogêneas e espacialmente distribuídas, detectadas pelo sensor, e podem ser contrastadas com outras representações de aplicações baseadas em percepção visual.

Mesmo com o uso dessa técnica que utiliza vetores 3D para formação das descrições e hipóteses e com a reivindicação dos autores de que seu uso melhora os resultados e também sua flexibilidade, a exemplo do que foi visto sobre as evoluções da abordagem do capítulo 2.1, esse trabalho demonstra apenas uma diferente aplicação de técnicas, não

tendo uma grande mudança em sua essência e não devendo, assim, ser considerada uma nova abordagem.

### 2.3 Orion

A abordagem do grupo Orion pode ser vista em (Hudelot, C. et al., 2004), (Maillot, N. et al., 2004) e (Hudelot, C., 2005). O grupo traz uma abordagem ao problema do ancoramento simbólico, descrito como a dificuldade de relacionar dados numéricos de uma imagem com dados semânticos que representam e dão significado ao conteúdo da imagem (LORENZATTI, A., 2008), conteúdo esse tratado por um sistema cognitivo que introduz uma nova camada entre o nível semântico e o nível da imagem, chamado de nível visual.

Dentro do trabalho do grupo Orion para resolução da interpretação do significado de uma imagem, são propostos 3 sub-problemas:

- O problema do processamento da imagem, que visa à extração de dados numéricos da imagem no baixo nível;
- o problema do ancoramento simbólico, já detalhado anteriormente;
- o problema da interpretação semântica, que consiste na extração de um significado da imagem.

Essas 3 áreas são divididas como mostrado na Figura 2.5 a seguir:

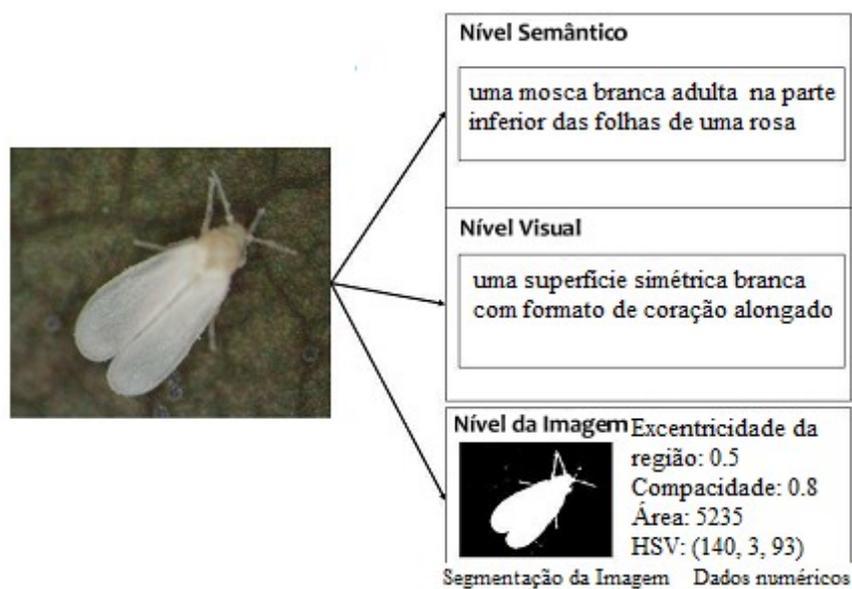


Figura 2.5: Os 3 níveis de abstração correspondentes aos sub-problemas representados através de uma imagem microscópica da biologia (HUDELOT, C. et al., 2004)

Essa subdivisão de problemas envolve ainda problemas de comunicação entre as camadas, resolvido através de ontologias intermediárias (o grupo Orion utilizou a definição de ontologia encontrada em (GRUBER, T. R., 1995): “especificação formal e explícita de uma conceitualização compartilhada”, considerando uma ontologia como sendo composta por um conjunto de conceitos  $C$ , um conjunto de relações  $R$  e um conjunto de axiomas). A primeira ontologia, responsável pela comunicação entre o nível semântico e o problema do ancoramento simbólico, ou simplesmente o nível visual,

chamada “ontologia de conceitos visuais” e a “ontologia de processamento de imagens”, responsável pela comunicação entre os níveis visual e de imagem.

A ontologia de conceitos visuais tem como meta ser um vocabulário comum utilizado por humanos para descrever objetos dentro de uma cena, ou seja, a descrição de conceitos semânticos. Ela foi composta por 115 conceitos, dos quais:

- Conceitos espaciais: 32 conceitos que definem formato, tamanho e localização e 32 conceitos referentes a relações espaciais, como topologia, distância e orientação;
- conceitos de cor: tendo em mente o formato HSL, é composto por 28 termos voltados à matiz (*Hue*), 4 à saturação (*Saturation*) e 5 à luminância (*Lightness*);
- conceitos de textura: contendo 14 tipos de texturas.

A ontologia de processamento de imagens tem como meta codificar formalmente os conceitos, propriedades e relações do processamento de imagens, definido como “o processo de manipulação e análise de imagens com um computador de acordo com um objetivo” (HUDELOT, C. et al., 2004). Composta por 183 conceitos, está dividida da seguinte forma:

- Conceitos de entidades de imagem: 11 conceitos representando diferentes estruturas de dados, como regiões, bordas, etc;
- conceitos de características de imagem: 167 conceitos, como medidas de tamanho (área, comprimento, etc.), formato (compacidade, excentricidade, etc.), dentre outros;
- conceitos de funcionalidades de processamento de imagens: 5 conceitos provenientes das intenções de dado processamento de imagem, dentre eles segmentação de imagem.

Dessa maneira, a ontologia deve funcionar de maneira que o nível superior possa requisitar dados, guiando a forma como devem ser entregues, bem como os dados entregues pelo nível inferior devem ser de fácil compreensão para o nível superior. Assim, ampliando o esquema da Figura 2.5, temos a inclusão das ontologias entre níveis, como pode ser observado na Figura 2.6:

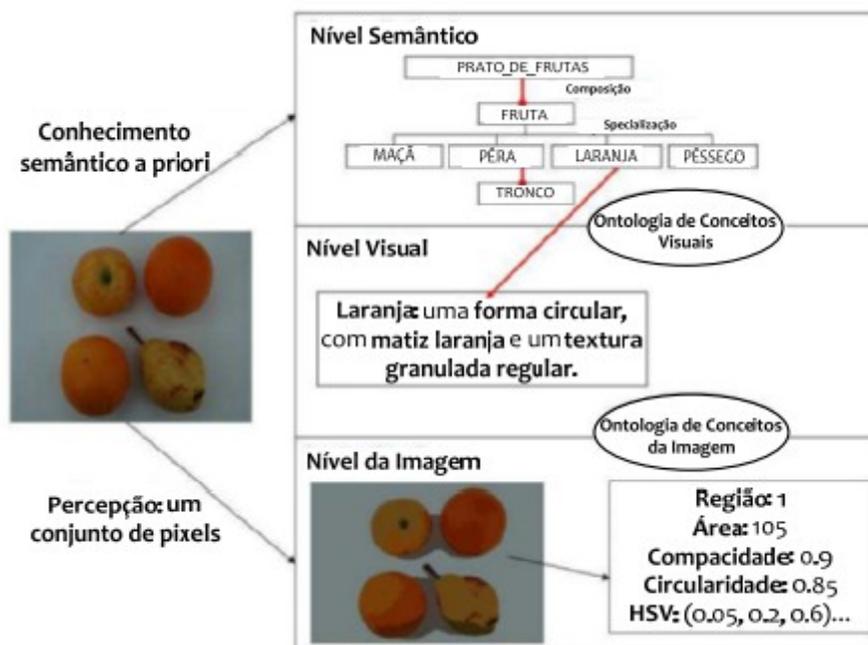


Figura 2.6: Ancoramento simbólico: 3 níveis e ontologias para comunicação (HUDELOT, C. et al., 2004)

A abordagem Orion sugere ainda dois métodos de trabalho para a interpretação semântica: conhecimento a priori e por aprendizado. O primeiro consiste em ter a ligação entre características dos dados da imagem no baixo nível e conceitos visuais construídos explicitamente, já o segundo tem essa ligação aprendida através de diversas imagens. O método por aprendizado é composto por duas etapas: seleção de características e treinamento.

A seleção das características é feita através da Análise Discriminante Linear (*Linear Discriminant Analysis – LDA*). Já a segunda etapa, o treinamento, é feita de maneira supervisionada, através de um conjunto de treinamento montado a partir de características extraídas de regiões de interesse apontadas por um especialista.

Apesar de mais próxima ao método de aprendizagem humano, a abordagem por aprendizado ainda tem alguns problemas, principalmente o fato de não conseguir aprender a estrutura espacial dos conceitos semânticos, assim não os levando em consideração para conseguir os resultados. Como é de se esperar, o método se torna mais eficiente à medida em que o conjunto de treinamento cresce.

No método do conhecimento a priori, uma base de conhecimento de ancoramento simbólico é previamente construída, como pode ser no exemplo da Figura 2.7 :

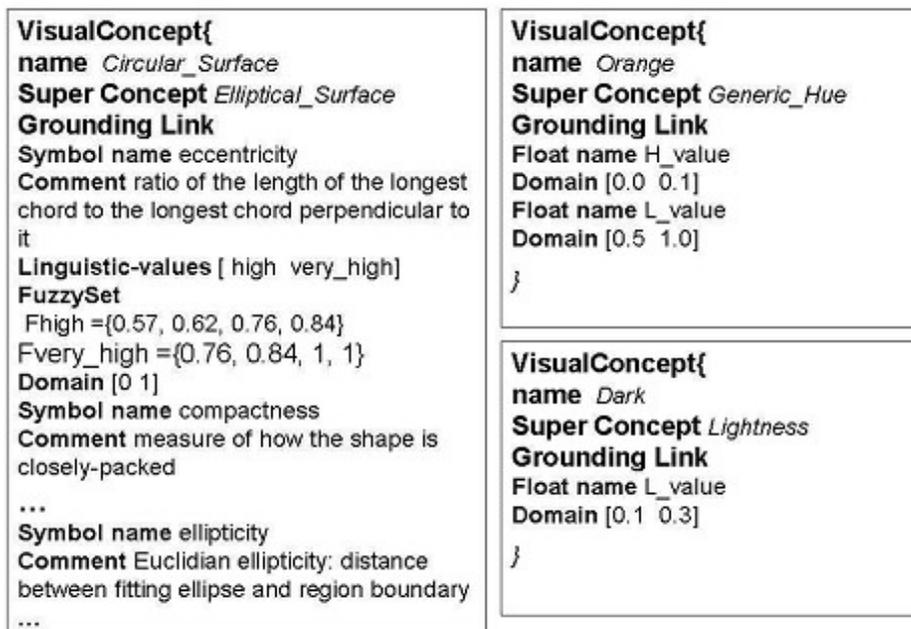


Figura 2.7: Exemplo de ancoramento simbólico construído a priori (HUDELOT, C. et al., 2004)

Como artefato ainda é utilizada a imprecisão de conjuntos *fuzzy* para modelar as características de baixo nível entre conceitos visuais e dados da imagem.

Dentro da abordagem Orion ainda é utilizada uma estratégia híbrida (podendo ser usado tanto *top-down* quanto *bottom-up*), ou ainda a ligação dos conceitos para formação do ancoramento simbólico pode ser feita de maneira manual.

### 2.3.1 Evoluções da abordagem Orion

Não parece haver evoluções da abordagem do grupo Orion até o momento, apenas algumas aplicações, como encontrado em (RAICU, D. S., E. et al., 2010).

## 2.4 Espaços Conceituais

A abordagem encontrada em (CHELLA, A. et al., 1997), (CHELLA, A. et al., 2001) e (GÄRDENFORS, P., 2004) – espaços conceituais – tem, nos seus primórdios, a área da visão computacional contextualizada na robótica. O termo é definido em (CHELLA, A. et al., 1997) como um espaço métrico consistindo em um número de dimensões cognitivas, incluindo cor, tamanho, etc. e trazendo uma

arquitetura cognitiva para um sistema de visão computacional, no qual uma representação interna efetiva do ambiente é construída através de processos definidos em um nível intermediário adequado que age como um intermediário entre os dados sensoriais e o nível simbólico. [...] Essa arquitetura visa prover um modelo geral de visão para um agente autônomo.

A abordagem dos espaços conceituais é dividida em 3 diferentes níveis, como pode ser visto na Figura 2.8:

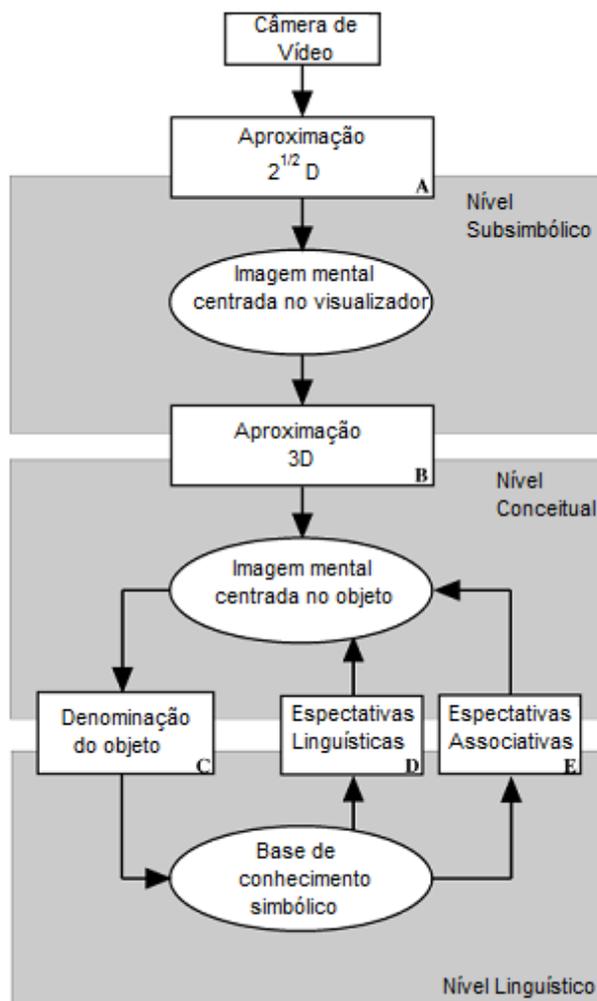


Figura 2.8: A arquitetura proposta pela abordagem dos espaços conceituais e seus 3 diferentes níveis (CHELLA, A. et al., 1997)

- **Nível Subsimbólico (*Subsymbolic Level*):** A informação é estritamente relacionada aos dados sensoriais, ou seja, à imagem bruta do baixo nível;
- **Nível Conceitual (*Conceptual Level*):** O nível intermediário no qual a informação é caracterizada em termos de um espaço métrico definido por um número de dimensões cognitivas, independente de qualquer linguagem. Em resumo: o core da abordagem dos espaços conceituais;
- **Nível Linguístico (*Linguistic Level*):** Onde a informação é expressada por uma linguagem simbólica.

As transições vistas na Figura 2.8 são realizadas da seguinte forma:

- “A” recebe a imagem de entrada de uma câmera e tem como saída um mapeamento chamado 2<sup>1/2</sup> D;
- “B” constrói uma descrição da cena em termos de combinações de primitivas geométricas 3D;
- “C” implementa o mapeamento entre o nível conceitual e simbólico;

- “D” implementa o modo linguístico do mecanismo de foco de atenção;
- “E” implementa o modo associativo do foco de atenção.

No seu nível mais baixo, o subsimbólico, a abordagem trata apenas de dados brutos vindos da imagem, sem a utilização de abstrações. Ao passar ao próximo nível, o conceitual, é utilizado o conceito de knoxel, definido como “um ponto genérico em um espaço conceitual (o termo knoxel é derivado por analogia de pixel). Um knoxel corresponde a uma entidade epistemologicamente primitiva no considerado nível de análise.” (CHELLA, A. et al., 2001, p.3), que se traduz como uma região da imagem. A seguir, na Figura 2.9, pode ser visto um exemplo da aplicação do conceito, sendo que cada  $k_i$  é um knoxel:

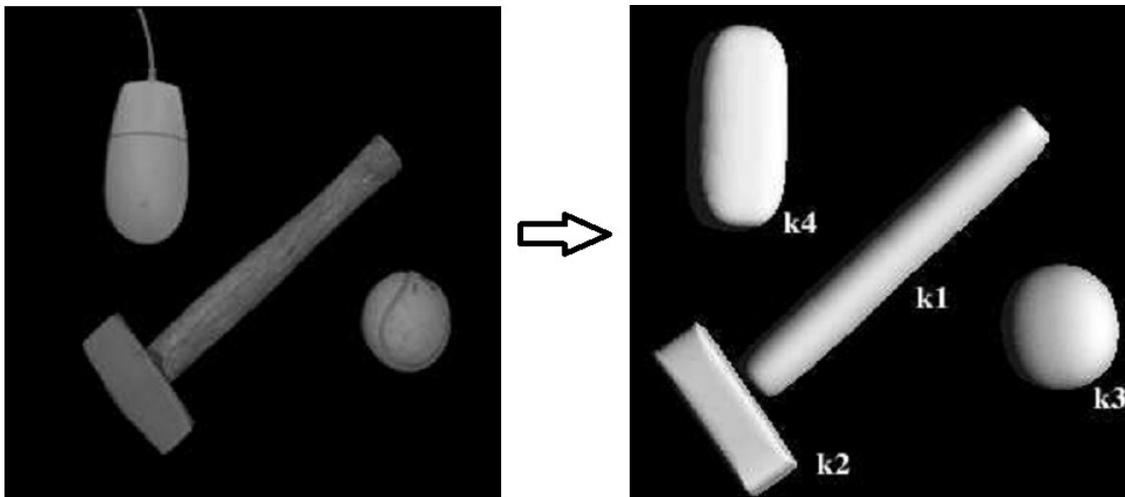


Figura 2.9: Uma imagem com seus objetos transformados em knoxels (CHELLA, A. et al., 1997)

Esses knoxels são formados através de superquadráticas – formas geométricas derivadas de uma equação paramétrica quadrática com funções trigonométricas elevadas a dois expoentes reais – representadas da seguinte forma:

$$f(\eta, \omega) = \begin{bmatrix} a_x \cos^{\varepsilon_1} \eta \cos^{\varepsilon_2} \omega \\ a_y \cos^{\varepsilon_1} \eta \sin^{\varepsilon_2} \omega \\ a_z \sin^{\varepsilon_1} \eta \end{bmatrix}$$

onde  $-\pi/2 \leq \eta \leq \pi/2$  e  $-\pi \leq \omega < \pi$ .  $a_x$ ,  $a_y$  e  $a_z$  são os comprimentos dos eixos e  $\varepsilon_1$  e  $\varepsilon_2$ , os fatores de forma, atuando, respectivamente, em relação à longitude e latitude do formato. Sendo que essa é a forma canônica de uma superquadrática, temos que o knoxels são representados, num ambiente 3D, com a adição de 3 coordenadas de centro  $p_x$ ,  $p_y$  e  $p_z$  e 3 ângulos de Euler  $\varphi$ ,  $\vartheta$ , e  $\psi$ :

$$\mathbf{k} = [ a_x \ a_y \ a_z \ \varepsilon_1 \ \varepsilon_2 \ p_x \ p_y \ p_z \ \varphi \ \vartheta \ \psi ]^T$$

Temos a seguir a Figura 2.10 para ilustrar a variação dos fatores de forma:

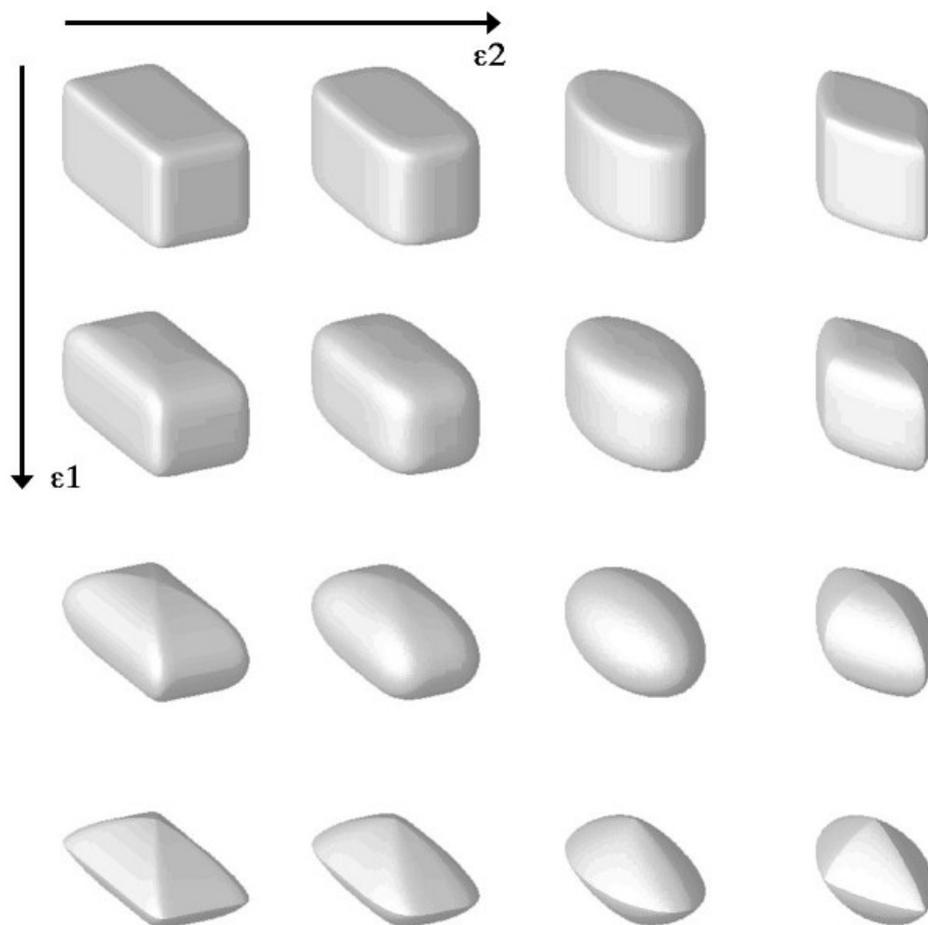


Figura 2.10: Variação dos fatores de forma (CHELLA, A. et al., 2001)

Passando ao nível linguístico, tendo em mente a necessidade de prover uma descrição concisa da cena em termos de uma linguagem lógica de alto nível, é utilizado um formalismo de representação híbrido, dividido em componente terminológico e componente assertivo. O primeiro componente contém as descrições de conceitos relevantes para o domínio representado, um modelo conceitual, já o segundo é composto pelas asserções descrevendo a cena. A divisão entre esses dois componentes é útil para a distinção entre o conhecimento conceitual e as asserções feitas para cada cena. A seguir, nas Figuras 2.11 e 2.12, são mostrados exemplos de conhecimento e situação no componente terminológico, respectivamente. O nível linguístico ainda permite o agrupamento de knoxels, permitindo assim a formação de objetos, como no caso do martelo na Figura 2.9, formado pelos knoxels  $k_1$  e  $k_2$ .

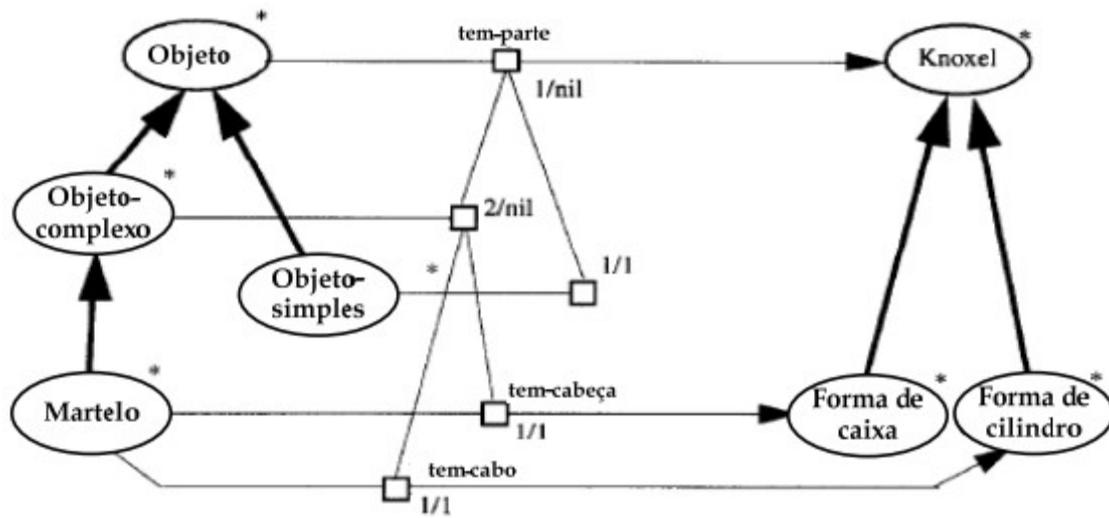


Figura 2.11: Fragmento de conhecimento no componente terminológico (CHELLA, A. et al., 1997)

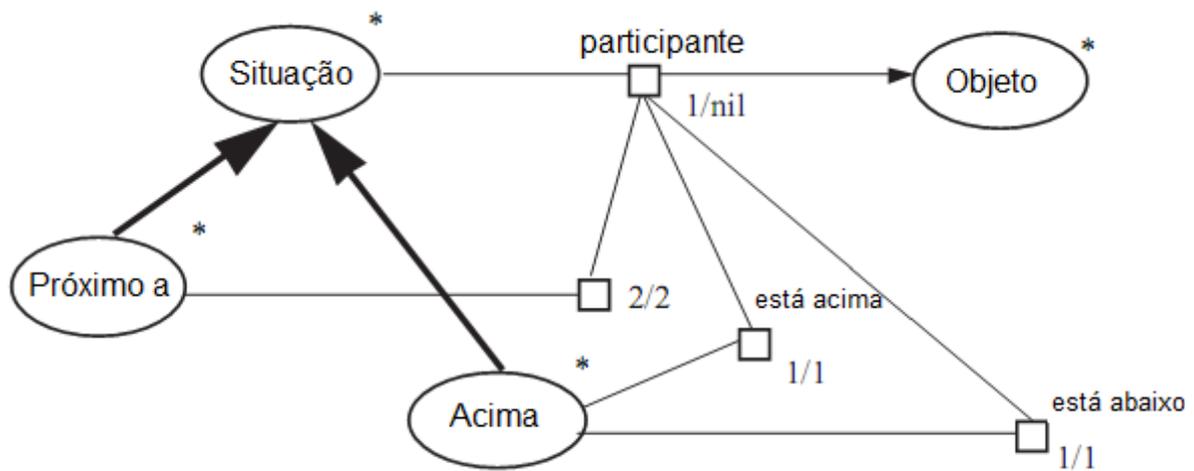


Figura 2.12: Situação no componente terminológico (CHELLA, A. et al., 1997)

Dessa forma podemos ter a representação de um martelo em um espaço conceitual, semelhante ao da Figura 2.9, como pode ser visto na Figura 2.13:

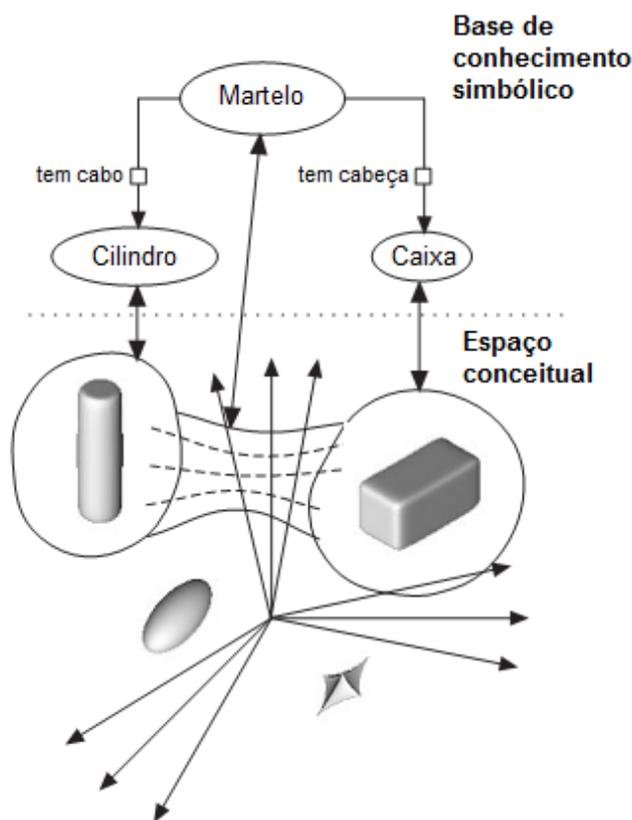


Figura 2.13: Martelo representado por seus knoxels em um espaço conceitual (CHELLA, A. et al., 2001)

#### 2.4.1 Evoluções da Abordagem dos Espaços Conceituais

A exemplo de outras abordagens, não há evoluções tão significativas a ponto de revolucionar a abordagem dos espaços conceituais, apenas algumas aplicações do trabalho como pode ser visto em (CHELLA, A. e S. GAGLIO, 2007) e (CHELLA, A. et al., 2008), essas mais voltadas à robótica.

## 2.5 Comparativo Entre as Abordagens

Após descrição mais detalhada de cada abordagem estudada, será feito um comparativo entre elas:

A abordagem dos agregados (NEUMANN, B. e R. MÖLLER, 2006) tem como características o uso de Lógica de Descrição (*Description Logics – DL*), o que torna a representação simples e mantém um bom nível formal. Os pontos fortes incluem a possibilidade de utilização em cenas com passagem de tempo, uma grande vantagem para sistemas em tempo real e possui também o que é a sua principal característica, a utilização dos agregados, procurando tirar conclusões de acordo com o contexto da cena, o que aproxima a abordagem de um comportamento mais natural. Entretanto, ela deixa de lado as dificuldades de interpretação de baixo nível, não provendo muitas informações sobre o modo como trata o problema do ancoramento simbólico, assumindo que isso não causará problemas, coisa que parece recorrente em alguns trabalhos acadêmicos, quando os autores parecem fugir do mundo real para criar um ambiente em que seus problemas não existirão e sua idéia poderá prosseguir sem

problemas. Outro fato que pode também ser considerado um ponto fraco é a falta de um nível intermediário na abordagem entre a imagem bruta e o nível mais alto, o que pode aumentar significativamente a complexidade do código para melhores resultados. Além disso, a maneira como é feita comunicação entre dados no baixo nível e alto nível não é explicitamente mostrada, levando a crer que seria feita através de dados brutos, ou seja, a partir do processamento da imagem já deveria haver a formação dos agregados, com a utilização do GSD e uma tradução posterior para, no caso, lógica de descrição para que o sistema possa ter suas conclusões.

A abordagem da abdução (SHANAHAN, M. e D. A. RANDELL, 2004) possui também a possibilidade de se trabalhar com imagens em movimento e conta com um forte formalismo: a Lógica de Primeira Ordem. Tem também como ponto forte o fato de haver interação com o usuário para melhorar a qualidade da cena que está sendo visto e, conseqüentemente, ter melhores resultados. Como pontos fracos da abordagem pode ser citada a declaração dos próprios autores de que ela funciona bem com exemplos simples, como reconhecimento de blocos de lego, mas não possui boa resposta com cenas mais complexas, algo que talvez pudesse ser melhorado se a abordagem não trabalhasse apenas com representações de linhas e regiões, mas sim com outros padrões, como cores e texturas. A exemplo do que é visto na abordagem dos agregados, a abordagem não possui uma forma de comunicação explícita entre os diferentes níveis da abordagem, apenas a formação de conjuntos de linhas e regiões, retiradas diretamente do processamento da imagem, que servirão para montar as teorias e fórmulas para conclusões do significado da imagem no alto nível; contudo, a abordagem abdução não especifica também, com clareza, o que se deve esperar como resultado no alto nível.

A abordagem Orion (HUDELOT, C. et al., 2004), (MAILLOT, N. et al., 2004) e [HUDELOT, C., 2005] possui a criação de um nível intermediário entre a imagem bruta e os dados semânticos e tem como ponto forte a divisão muito clara entre seus três níveis, bem como a comunicação entre eles que é feita por ontologias, fazendo com que a abordagem possua um bom nível de abstração e clareza. Outra característica a favor da abordagem é o fato de ter sido utilizado em aplicações reais e ser um trabalho bem completo, o que serve como uma base mais forte para posteriores aplicações. Contudo, o fato de ser um trabalho tão complexo faz com que ele possa se tornar inviável, dependendo da área a ser aplicado. Também é um trabalho que deixa a desejar pela falta de possibilidade utilização de cenas em movimento e o fraco resultado quando se utiliza o método por aprendizado e não conhecimento a priori.

Finalmente, a abordagem dos espaços conceituais (CHELLA, A. et al., 1997), [CHELLA, A. et al., 2001] e (GÄRDENFORS, P., 2004), a exemplo da abordagem Orion, possui a criação de um nível intermediário entre a imagem bruta e os dados semânticos, deixando bem clara a divisão entre os níveis alto, intermediário e baixo. Torna-se uma abordagem interessante pelo fato da introdução do conceito de knoxel, possibilitando assim representações a partir de um espaço 3D e composição de objetos complexos a partir de modelagens simples. Porém, a exemplo do que é visto na abordagem abdução, só é levada em consideração a forma dos objetos, deixando de lado algumas características importantes.

Assim, temos algumas das principais características evidenciadas na tabela 2.1.

Tabela 2.1: Comparação entre abordagens semânticas de reconhecimento de objetos

<b>Abordagens</b>				
	<b>Agregados</b>	<b>Abdução</b>	<b>Orion</b>	<b>Espaços conceituais</b>
<b>Formalismo de Representação</b>	Lógica de Descrição (Description Logics – DL)	Lógica de Primeira Ordem	Frames	Frames e Lógica, mas não especifica o tipo
<b>Aplicação Básica</b>	Interpretação de Cenas	Controle de Tráfego e Robótica	Interpretação de imagens estáticas	Robótica
<b>Tipo de Ancoramento Simbólico</b>	Possivelmente híbrido (top-down e bottom-up)	Híbrido (top-down e bottom-up)	Híbrido (top-down e bottom-up) e Manual	Híbrido (top-down e bottom-up)
<b>Processamento de Imagem</b>	Utiliza GSD	Detecção de arestas e regiões	Detecção de regiões, ou seleção manual	Detecção de regiões
<b>Implementação</b>	Utiliza sistema RACER	Utiliza C++ e Prolog	Em (HUDELOT, C., 2005) utilizou a plataforma LAMA (CRUBÉZY, M. et al., 1998)	Menciona uso dos sistemas TEA-1 (RIMEY, R. D., 1993) e BUSTER (BIRNBAUM, L., 1993)
<b>Número de Níveis</b>	2 níveis explícitos	2 níveis explícitos	3 níveis explícitos	3 níveis explícitos
<b>Níveis Utilizados</b>	Não são explicitadas nomenclaturas para os níveis	Não são explicitadas nomenclaturas para os níveis	Semântico, Visual e da Imagem	Subsimbólico, Conceitual e Linguístico
<b>Comunicação Entre Níveis</b>	Dados Brutos	Dados Brutos	Ontologias	Knoxels entre níveis Conceitual e Linguístico.

Com a análise feita ao longo do capítulo e resumida na tabela 2.1 acima, pode-se concluir que a abordagem Orion é a melhor formulada dentre as quatro. Contudo, deve-se manter em mente que cada uma foi proposta com objetivos diferentes e tendem a mostrar alguma dificuldade na extensão para outros tipos de abordagem.

## 3 O FRAMEWORK S-CHART E O SISTEMA INTELISTRATA

O trabalho de Fiorini, S. R. (2009 e 2010) apresenta duas ferramentas para a análise semântica de gráficos: o *framework* S-Chart e o sistema Intelistrata. Sendo o primeiro um *framework* geral para interpretação de gráficos e o segundo uma aplicação para estratigrafia de sequências, que será vista em mais detalhes na seção 3.3.

### 3.1 Framework S-Chart

Criado a partir das linguagens OWL e Java, o *framework* S-Chart tem como foco a interpretação semântica de gráficos através da combinação de algoritmos de processamento de sinais com algoritmos e modelos de raciocínio simbólico. A partir disso o *framework* utiliza os seguintes conceitos:

- Incorporação de ontologias de domínio;
- Primitivas de modelagem independentes de domínio;
- Ancoramento simbólico explícito;
- Modelo processável por computador.

A arquitetura do *framework* S-Chart é dada pela divisão em três componentes: o componente de representação que, a exemplo dos trabalhos de (HUDELLOT, C., N. MAILLOT, et al., 2004), (MAILLOT, N., M. THONNAT, et al., 2004) e (HUDELLOT, C., 2005), é dividido em três níveis (Semântico, Visual e Analógico); o componente de mapeamento, destinado ao ancoramento simbólico, e o componente de interpretação, responsável pela inferência e interpretação das informações visuais, como pode ser visto na Figura 3.1 a seguir:

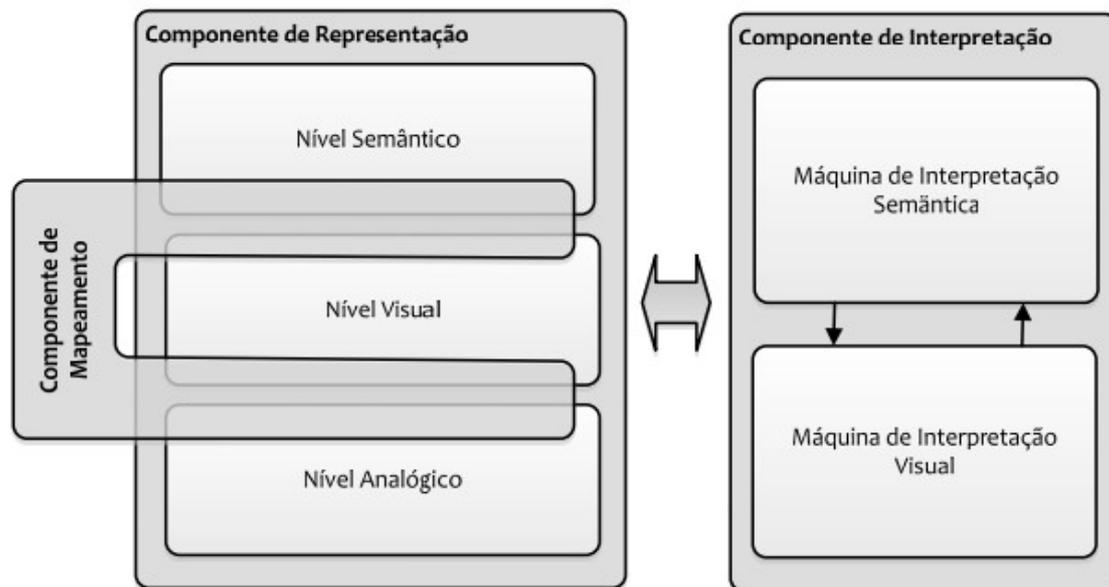


Figura 3.1: Arquitetura do *framework* S-Chart (FIORINI, S. R., 2009)

O componente de representação é composto pelos níveis semântico, visual e analógico. O nível semântico é responsável pelo modelo de conhecimento e suas ontologias de domínio. O visual é composto por feições visuais genéricas, independentes de domínio, contendo noções de formas visuais básicas como pontos, retas e curvas; e também relações como proximidade, comparações de tamanhos, etc. Por fim, o nível analógico é também independente de domínio e diretamente ligado a algoritmos de processamento de imagens para extração de elementos necessários para reconhecimento no nível visual.

O componente de mapeamento, responsável pelo ancoramento simbólico, associa os elementos da imagem ao seu correspondente e é definido de uma maneira que apenas possa haver o mapeamento de um nível do componente de representação para o nível vizinho. Assim, entidades do nível analógico somente poderão ser mapeadas para o nível visual e então essas entidades do nível visual para o semântico, não sendo permitido o mapeamento direto de, por exemplo, um conjunto de pixels do nível analógico para uma entidade do nível semântico, digamos, um carro.

O componente de interpretação, responsável por processar o sinal em conjunto com os modelos de representação e ancoramento simbólico até que seja inferido algum objeto do domínio presente no sinal é, talvez, o componente mais interessante dentro do *framework* S-Chart e possui sua arquitetura interna contendo duas máquinas de interpretação, uma semântica e outra visual. Seu funcionamento se dá a partir de um sinal de entrada contendo a imagem a ser analisada, que será processada pela parte responsável pelo processamento de sinal, e uma entidade do domínio, uma hipótese que será procurada nesse sinal.

Desse modo, a máquina de interpretação semântica do componente de interpretação “tenta confirmar a presença de conceitos do domínio com base nas suas extensões no nível visual, definidos por detectores simbólicos” (FIORINI, S. R., 2009, p.55). Já a máquina de interpretação visual extrai as primitivas visuais do nível analógico através do acionamento de algoritmos de processamento de sinal e da utilização de seus próprios detectores simbólicos.

A arquitetura do componente de interpretação, que possui como saída as instâncias de conceitos do domínio relacionados à hipótese inicial de busca através de uma abordagem mista na qual utiliza raciocínio *top-down* e *bottom-up*, pode ser visto em mais detalhes na Figura 3.2.

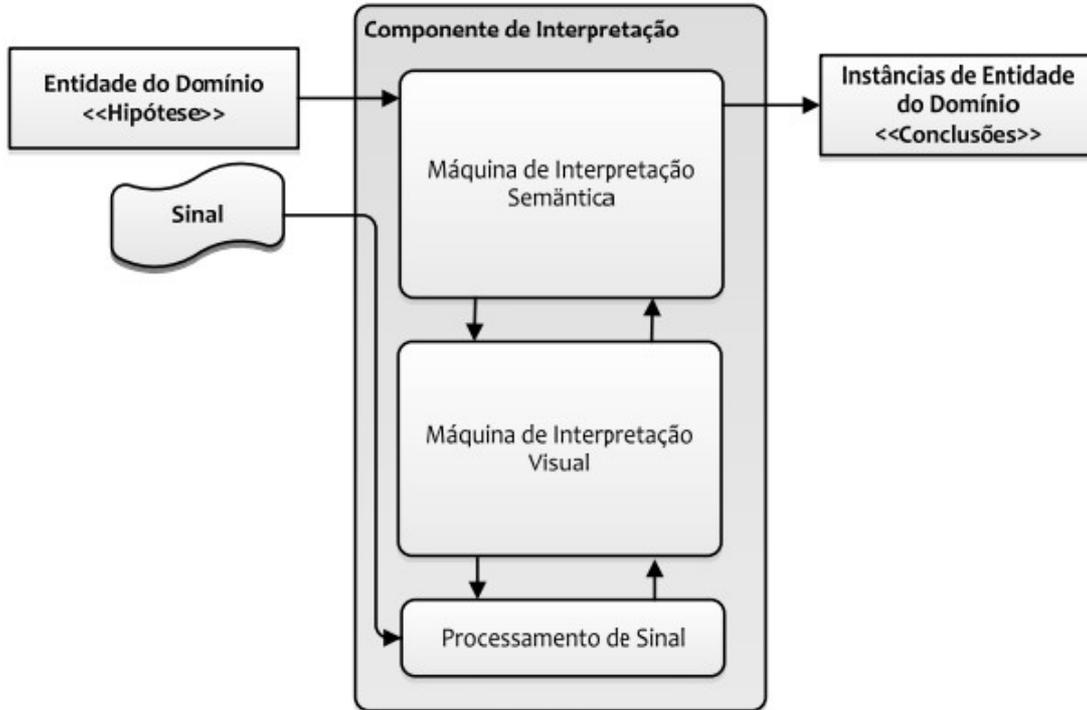


Figura 3.2: Arquitetura do Componente de Interpretação (FIORINI, S. R., 2009)

### 3.2 Sistema Intelistrata

O sistema Intelistrata consiste na aplicação do *framework* S-Chart no domínio da Estratigrafia de Sequências, uma sub-área da Geologia. O sistema, arquitetado de maneira que pode ser vista na Figura 3.3, sugere interpretações estratigráficas de perfis de raios gama.

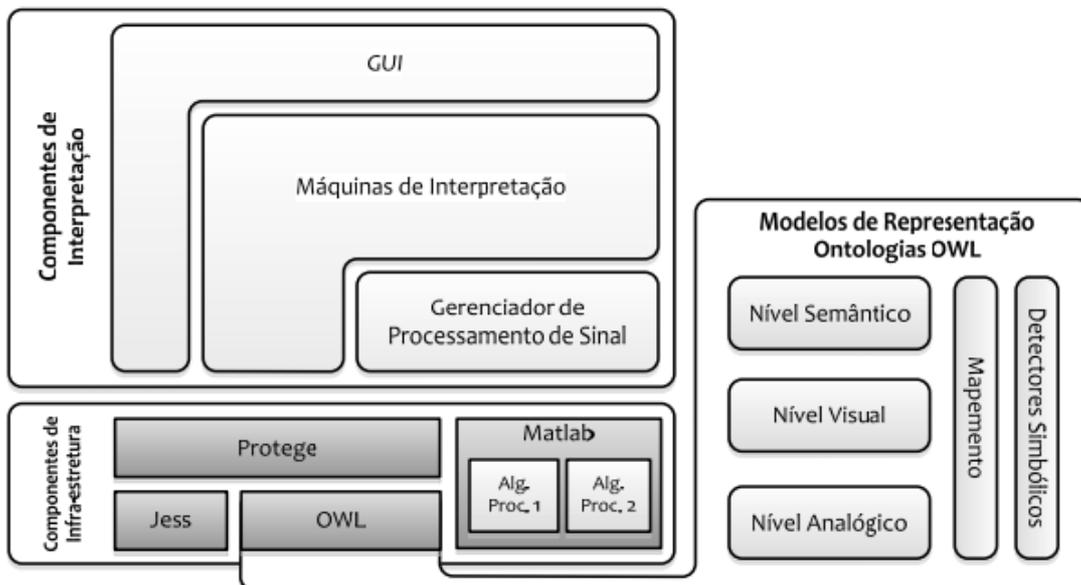


Figura 3.3: Arquitetura do sistema Intelistrata (FIORINI, S. R., 2009)

Para a criação do sistema Intelistrata foram propostas extensões sobre o *framework* S-Chart. Por exemplo, são incluídas ontologias – todas criadas em OWL – da área de estratigrafia de seqüências. É importante salientar que não existe uma ontologia própria para esta área; uma ontologia foi criada a partir do conhecimento de alguns especialistas na área durante o desenvolvimento do trabalho de (FIORINI, S. R., 2009).

Há também extensões no nível analógico e visual do *framework* S-Chart, proporcionando um maior alcance ao tema proposto, a Estratigrafia de Sequências. É importante lembrar que o *framework* S-Chart foi construído com um propósito geral e toda aplicação feita a partir dele pode incluir extensões tornando-o mais completo para diversas áreas e seus resultados mais satisfatórios. Isso é o que vemos com o sistema Intelistrata.

Essas extensões formam, juntamente com a parte original do *framework* S-Chart, o componente chamado “Modelos de Representação” na arquitetura do sistema na Figura 3.3.

Os componentes de infra-estrutura na arquitetura do sistema Intelistrata são os componentes desenvolvidos por terceiros que dão suporte ao seu funcionamento. Sua utilização é justificada por Fiorini (2009), no caso do sistema Protege por ser uma das mais populares ferramentas de manipulação de OWL no momento do desenvolvimento do sistema, sendo que essa linguagem foi considerada suficiente para o proposto e ainda a ferramenta possui a disponibilidade de extensão pelo próprio usuário. Já o software Jess foi escolhido para execução das regras utilizadas no sistema e por sua facilidade de integração com o Protege. A parte de processamento numérico fica a cargo do Matlab R2008a, por disponibilizar diversos pacotes de processamento de dados numéricos e de sinal.

Por fim, o componente de interpretação da arquitetura do sistema Intelistrata é composto por uma GUI (componente de interface gráfica) simples, que permite a seleção do arquivo a ser analisado e a exibição de seus resultados; pelas máquinas de interpretação semântica e visual, como mencionado na seção 3.1 e pelo gerenciador de processamento de sinal, responsável pela delegação e gerenciamento dos algoritmos de processamento de sinais do sistema.

### 3.3 Estratigrafia de Sequências

Estratigrafia de seqüências é o mais recente paradigma revolucionário no campo de geologia sedimentar. Os conceitos incorporados por essa disciplina resultaram em uma mudança fundamental na maneira de pensar geologia e, em particular, os métodos de fácies e análises estratigráficas. Ao longo dos últimos quinze anos essa abordagem tem sido aceita por geocientistas como o estilo preferido de análise estratigráfica, que tem servido para fazer a ligação entre diversas disciplinas. De fato, um aspecto chave da abordagem de estratigrafia de seqüências é encorajar a integração de conjuntos de dados e métodos de pesquisa. Unir conhecimentos de diversas disciplinas invariavelmente leva a interpretações mais robustas e, conseqüentemente, progresso científico. Assim, a abordagem da estratigrafia de seqüências tem levado a um melhor entendimento de como unidades estratigráficas, tratos de sistemas e unidades deposicionais se relacionam em tempo e espaço dentro de bacias sedimentares. A aplicação de estratigrafia de seqüências tem amplo campo de aplicações, desde exploração preditiva de petróleo, carvão e delimitação dos depósitos, até melhor entendimento das mudanças geológicas locais e globais da Terra. (CATUNEANU, O., 2006, p.1)

A Estratigrafia de Sequências é a área da Geologia responsável pelo estudo da formação dos estratos do subsolo pela variação do mar e deposição de matéria orgânica. Sua correta interpretação permite uma boa predição do que pode ser encontrado em dado local, o que é de grande ajuda para atividades como a extração de petróleo.

Há diversas maneiras de estudos para predição do material em dada área, como os *perfis de poços*, que “representam registros geofísicos de propriedades de rochas em diferentes poços” (CATUNEANU, O., 2006, p.40). Dentre as principais vantagens do uso de perfis de poços, que faz medidas indiretas sobre as propriedades de rochas está o custo reduzido em relação à extração de rochas. É possível aproximar o perfil da região através do uso de diferentes tipos de perfis que possuem, por sua vez, diferentes interpretações geológicas e devem ser combinados para resultados mais precisos. O sistema Intelistrata utiliza o perfil de raios gama, que consiste em medir radioatividade natural, por exemplo, o decaimento de Potássio, Tório e Urânio nas rochas, o que reflete indiretamente a quantidade de argilominerais, indicando assim, a ocorrência de sedimentos finos e grossos. Essa medição gera um perfil, uma curva, a exemplo do que pode ser visto na Figura 3.4, a partir da qual um especialista, ou um sistema como o Intelistrata, é capaz de dizer, pelo formato visual das curvas em quais trechos deve haver sequências deposicionais, podendo assim identificar intervalos de interesse para posterior prospeção de petróleo no local.

Uma sequência deposicional, segundo as palavras de Catuneanu (2006), pode ser considerada a parte fundamental da estratigrafia de sequências. Ela corresponde aos pacotes de rochas depositados durante um ciclo completo de mudanças no nível básico do mar ou transições das linhas costeiras dependendo do modelo de sequência deposicional que está sendo aplicado. Elas são “uma sucessão relativamente concordante de estratos geneticamente relacionados delimitadas por discordâncias ou suas conformidades correlativas”. Essas sequências deposicionais são um histórico do que houve com determinada região ao longo dos anos e podem representar o tipo de material orgânico que ali se encontra. Uma parassequência, por sua vez, marca ciclos menores de oscilação do nível do mar e sua delimitação é sempre intena à sequência deposicional. Superfícies de inundação máxima são os estratos que identificam a inversão do ciclo de subida do nível do mar.

No capítulo a seguir será mostrado um novo algoritmo, com auxílio de médias móveis, na tentativa de identificar padrões interessantes do perfil de raios gama, como por exemplo quedas abruptas, deixando a cargo do sistema inferir seu significado (no caso sabemos que será um limite de sequência deposicional). A abordagem proposta deve fornecer como saída objetos possíveis interpretação semântica pela arquitetura adotada.

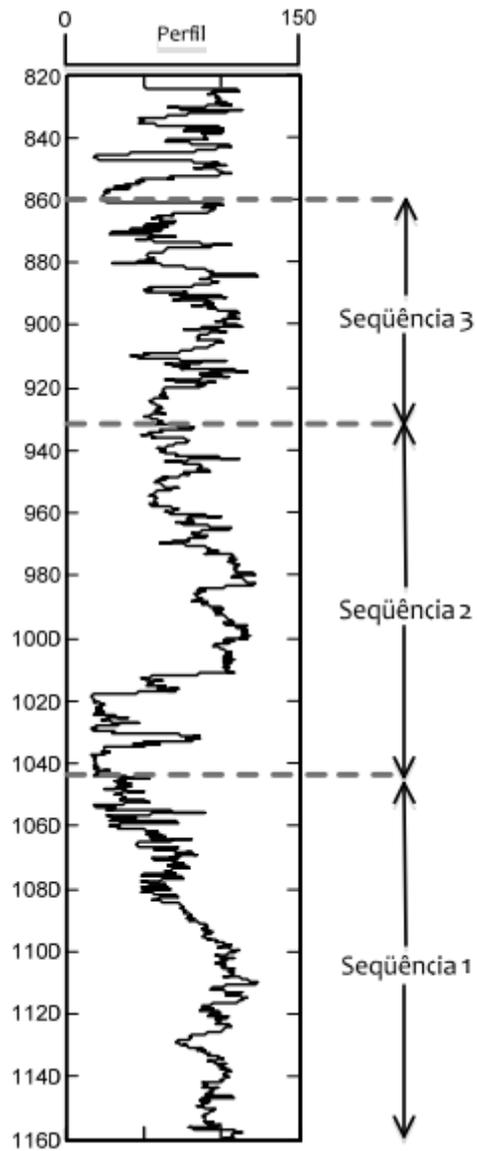


Figura 3.4: Exemplo de Perfil de Raio Gama. Editado de (FIORINI, S. R., 2009)

## 4 UM NOVO ALGORITMO

Nesta seção será discutida uma nova abordagem para o algoritmo de processamento de sinal, que visa tentar melhorar os resultados do sistema Intelistrata, tendo foco no nível analógico do sistema. Ela deverá ser utilizada em conjunto com os demais componentes do sistema, sem alterações significativas nos mesmos, apenas o suficiente para a integração do novo algoritmo com o sistema.

### 4.1 O novo algoritmo

O sistema Intelistrata tem como objetivo principal a busca de sequências deposicionais, parassequências e superfícies de máxima inundação. Neste trabalho estamos interessados apenas na melhora da identificação dos limites de sequências deposicionais. Posteriormente, melhorias podem ser feitas na delimitação de parassequências e identificação de superfícies de máxima inundação.

Segundo um geólogo especialista, a identificação dos limites de sequências deposicionais, quando analisado apenas o perfil de raios gama, se dá por uma queda abrupta no valor do gama. Dessa maneira, fica evidenciado que o problema maior do sistema Intelistrata está em seu processamento de sinal no qual busca, através da transformada *wavelet*, encontrar certos padrões na curva, mais precisamente um tipo de gaussiana. Isso pode ser feito de uma maneira mais precisa com outros métodos pois ao invés de tentar analisar o comportamento de uma curva para identificar tais quedas o sistema busca por padrões que podem não acusar essa queda, já que mesmo que se quisesse prosseguir na tentativa de aproximações de curvas, uma no estilo “dente-de-serra” talvez fosse mais apropriada.

A transformada *wavelet* é feita tendo em vista a procura de semelhanças da curva do perfil de raio gama com uma curva gaussiana do tipo gaussiana 2, como mostrado na Figura 4.1.

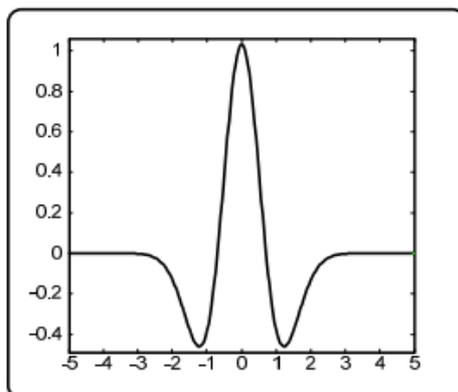


Figura 4.1: *Wavelet* Gaussiana 2 (FIORINI, S. R., 2009)

Quando o sistema Intelistrata encontra um dado intervalo do perfil semelhante a uma curva guassiana, em certo nível pré-definido, ele assinala essa região para posteriormente ser testado pelo sistema como uma região de sequência deposicional. O principal problema dessa abordagem é o fato de buscar *semelhanças*, e não *comportamentos* da curva do perfil de raios gama. Segundo o especialista da área, dentro desse perfil, os limites de sequências deposicionais são identificados por quedas abruptas no gráfico, ou seja, no valor gama do perfil no ponto analisado. Dessa forma, qualquer queda brusca que ocorra e não tenha certa semelhança com a *wavelet* gaussiana será ignorada pelo sistema Intelistrata, mesmo curvas a exemplo das dente-de-serra, como a da Figura 4.2, que podem representar ainda melhor uma queda desse tipo.

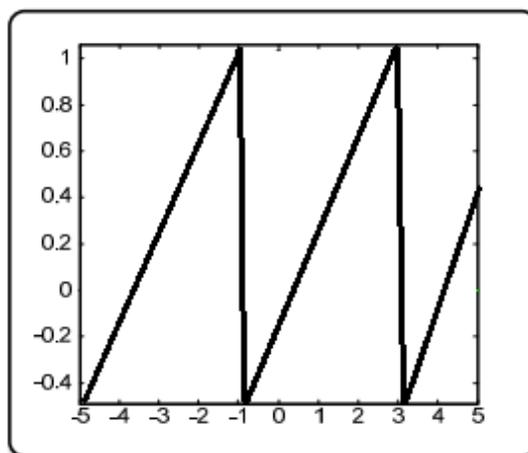


Figura 4.2: Exemplo de curva dente-de-serra

Entretanto, mesmo que fosse utilizada outra curva, o problema original permaneceria: a busca por um padrão de curva ao invés da verificação do comportamento dela.

Especialistas na área costumam, além de buscar tais quedas, enxergar tendências de subida e descida dentro dos perfis para ajudar-lhes na marcação dos limites de sequências deposicionais. Tentou-se recriar esses artefatos com utilização de médias móveis, como será apresentado nas próximas subseções.

### 4.1.1 Curva de Tendências

As curvas de tendências mostram para onde o valor geral do gráfico no perfil de raios gama está se deslocando. Ele ajuda a verificar se temos uma tendência de ascensão ou queda. Isso serve como ferramenta para que geólogos especialistas na área consigam verificar mais facilmente propriedades da curva.

Um tipo de ferramenta que pode ser utilizado para acompanhar a tendência de uma curva é a ferramenta de médias móveis, comumente utilizada na análise de tendência do valor de ações na bolsa de valores. Uma média móvel é chamada dessa maneira pois ela *movimenta-se* ao longo de uma parte da informação disponível. Por exemplo, se estão disponíveis mil pontos e deseja-se calcular a média móvel com uma janela de 50 pontos, a média móvel calculará cada um de seus valores levando-se em conta os 49 pontos anteriores ao ponto em questão e ele próprio. Assim, se quisermos saber o valor da média móvel no ponto 100, será feita a média dos valores nos pontos 51 a 100 da informação original. Para o ponto 101 serão utilizados os valores de 52 a 101, no ponto 500, os valores de 451 a 500 e assim sucessivamente. Ainda existem diversos tipos de médias móveis, dentre os principais as médias móveis simples, que fazem a média aritmética dos pontos dentro da janela e médias móveis ponderadas, que distribuem diferentes pesos aos pontos dentro da janela. Ainda há uma interessante ferramenta que pode ser utilizada juntamente com médias móveis chamada *regressão linear*. Essa regressão serve para estimar o próximo ponto levando-se em questão os pontos anteriores aplicados a uma função linear, o que além de originar o nome da ferramenta faz com que o comportamento traçado pela média seja mais suave, não sendo tão fortemente alterado por pontos muito distantes à tendência do gráfico no local.

Para descobrir-se a tendência da curva em dado ponto são feitos os 4 seguintes passos: (1) calcula-se a média móvel para toda a curva, (2) então é feito o somatório dos valores dessa média nos 40 pontos antecessores ao ponto em questão. (3) Ao verificar-se esse somatório pode-se inferir que a tendência da curva é de subida caso o resultado seja positivo, ou então infere-se que a tendência é de queda caso o resultado seja negativo. (4) No caso do somatório resultar zero, considera-se que a tendência continua sendo a mesma do ponto anterior. Chegou-se ao valor 40 a partir de testes empíricos, sendo que ele foi o que mostrou da melhor maneira o comportamento geral da curva, ignorando alterações mais bruscas, que poderiam ser considerados como um ruído no sinal.

A curva aqui utilizada é do tipo *Lowess*, um tipo de média móvel ponderada com regressão linear.

Essas decisões (tipo de curva e número de pontos a serem verificados) foram tomadas, além de utilizar a experiência do autor deste trabalho e algumas justificativas matemáticas como a natureza da curva e o porquê dela apresentar bom comportamento no caso, a partir de verificação, junto com o especialista, do que ele considera que estava próximo ou não do que ele visualiza ao buscar essas tendências.

Um exemplo da curva de tendências pode ser visto na Figura 4.3, levando-se em conta que a análise deve ser feita da maior para a menor profundidade, sendo que aqui temos outro possível problema no sistema Intelistrata, que faz a verificação no sentido oposto.

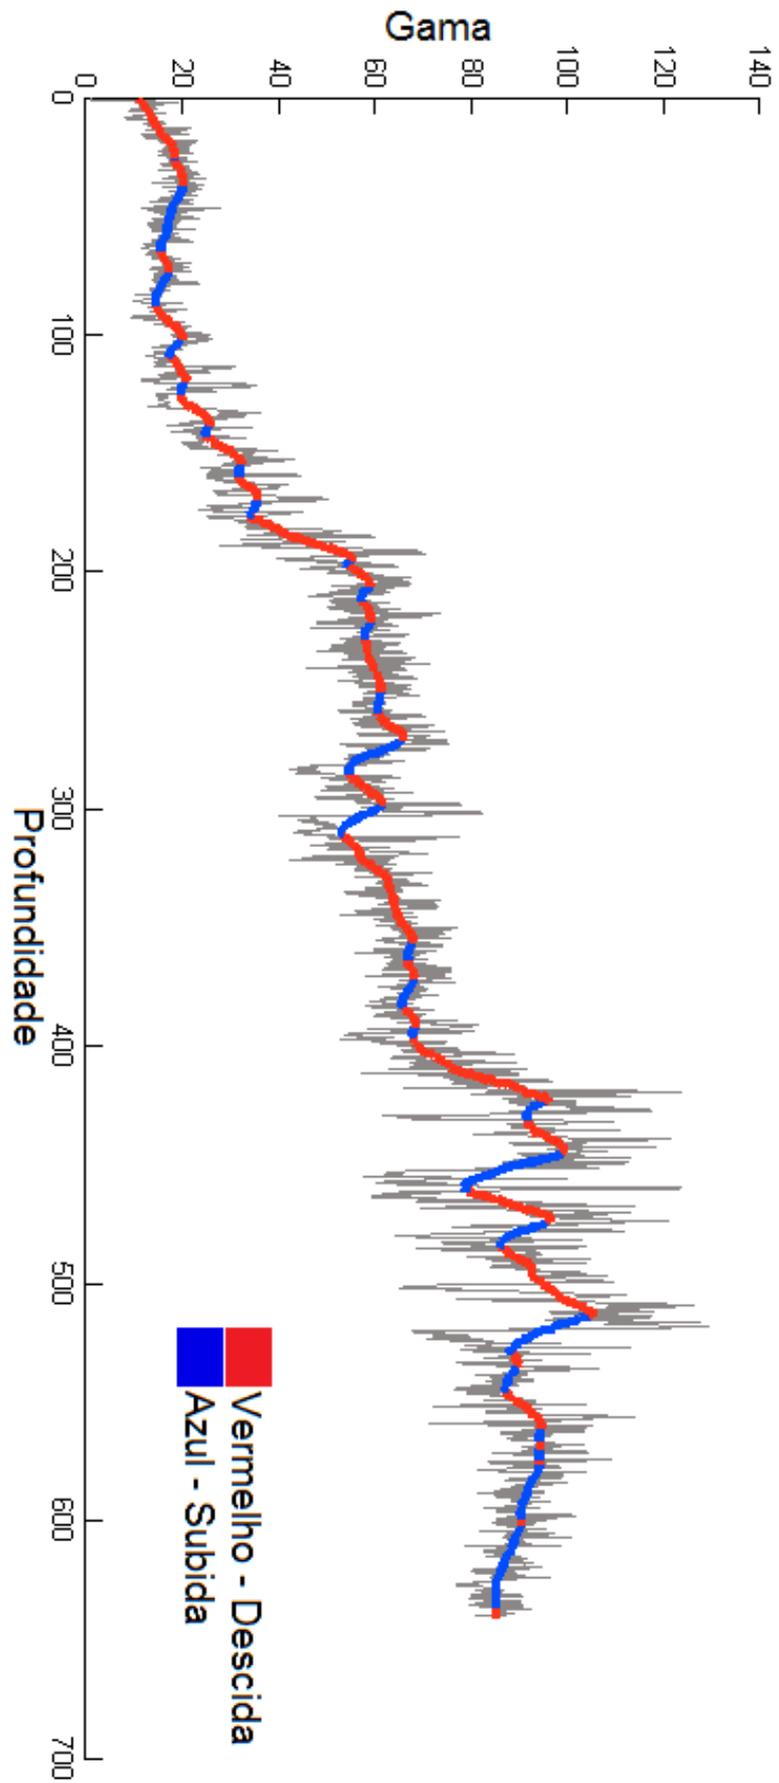


Figura 4.3: Curva de tendências

#### 4.1.2 Limites de Sequências Depositionais

Apesar de manter a mesma filosofia das curvas de tendência (utilização de médias móveis e possíveis analogias com investimento em bolsa de valores), o problema aqui se torna um pouco mais complicado e exige um maior tratamento pelo seu maior nível de detalhes.

Inicialmente se pensou na possibilidade de alterar a *wavelet* utilizada na tentativa de identificar os limites de sequências deposicionais, idéia refutada posteriormente pelas razões já citadas neste mesmo capítulo. Após isso foi iniciada a abordagem com ajuda das médias móveis, procurando uma maneira de identificar quedas bruscas. A partir de então, deu-se uma série de tentativas:

- Verificação se a média de quedas dos últimos pontos do valor gama (aqui escolhendo-se uma quantidade de pontos arbitrária) está dentro ou fora do desvio padrão das alterações no gráfico, considerando-se que uma queda acima do valor do desvio padrão pode identificar uma alteração brusca e possível limite de sequência deposicional. Essa idéia a princípio parecia boa e como todas as subsequentes contribuiu para chegar-se ao algoritmo final, mas seu grande problema é que não permite a detecção de quedas bruscas com a precisão necessária. Isso por que caso haja uma queda brusca mas essa tenha sido formada por uma sequência de quedas beirando o desvio padrão, mas ainda dentro dele, não será considerada uma queda brusca, pois sua média continua dentro desse desvio padrão. Por exemplo, se são escolhidos 5 pontos para formar-se a média e o desvio padrão para o gráfico analisado tem um valor 4 (aqui a unidade não chega a ser relevante, mas poderíamos considerar pés ou metros para o caso de perfis de poços), caso os últimos 5 pontos tenham quedas constantes de um valor 3,9 (aqui a mesma unidade utilizada para o desvio padrão), sua média será 3,9, ainda dentro do limite estabelecido pelo desvio padrão, mas provavelmente uma sequência de quedas assim mostraria uma queda brusca. Indo além, aqui o desvio padrão é considerado para todo o gráfico, não regiões específicas, como exemplificado pela Figura 4.5.
- Modificação da abordagem anterior, utilizando a média móvel adaptativa de Perry Kaufman (KAUFMAN, P. J., 1998), ao invés do valor gama para cálculo do desvio padrão. O problema em regiões com sequências de quedas dentro do desvio padrão foi amenizado, mas não totalmente excluído e ainda não havia a noção de que o desvio padrão deveria ser considerado para regiões diferentes, ao invés de considerar-se o todo. Adiante será abordado o motivo de se fazer o cálculo por regiões.
- Utilização da idéia de que uma queda brusca costuma ser identificada por uma “falha” no gráfico, como mostra a Figura 4.4. Para tal é feita a identificação de um período no qual o valor do gama permanece abaixo do valor da média, o que identifica um período de queda, o que por si só pode mostrar que ela seja possivelmente abrupta, já que a média está demorando a ter um valor próximo ao gama. Identificada a queda, retorna-se à tentativa de verificar se tal queda realmente se deve a uma alteração brusca, então é utilizada a verificação do desvio padrão dentro do valor gama. Nesta abordagem retornam os problemas das anteriores e ainda há o problema de se definir o intervalo que o valor gama deve permanecer abaixo da média para ser considerado uma queda brusca.

- Inserção da noção de que a queda brusca é notada visualmente; portanto, seu valor absoluto em uma região de pequena amplitude certamente não será o mesmo que em uma região de grande amplitude, como exemplificado na Figura 4.5, na qual temos 3 regiões de amplitudes distintas e nota-se que a amplitude da queda brusca assinalada pode ser muito diferente de uma região para outra. Dessa forma, desvios padrões e “falhas” no gráfico devem ser calculados em uma região relativa ao ponto examinado, não ao gráfico por completo. Aqui os problemas relativos à identificação do intervalo necessário abaixo da média prosseguem, mas nota-se uma melhora na identificação de pontos em que as alterações são maiores que o desvio padrão da região.



Figura 4.4: “Falha” devido a uma queda brusca

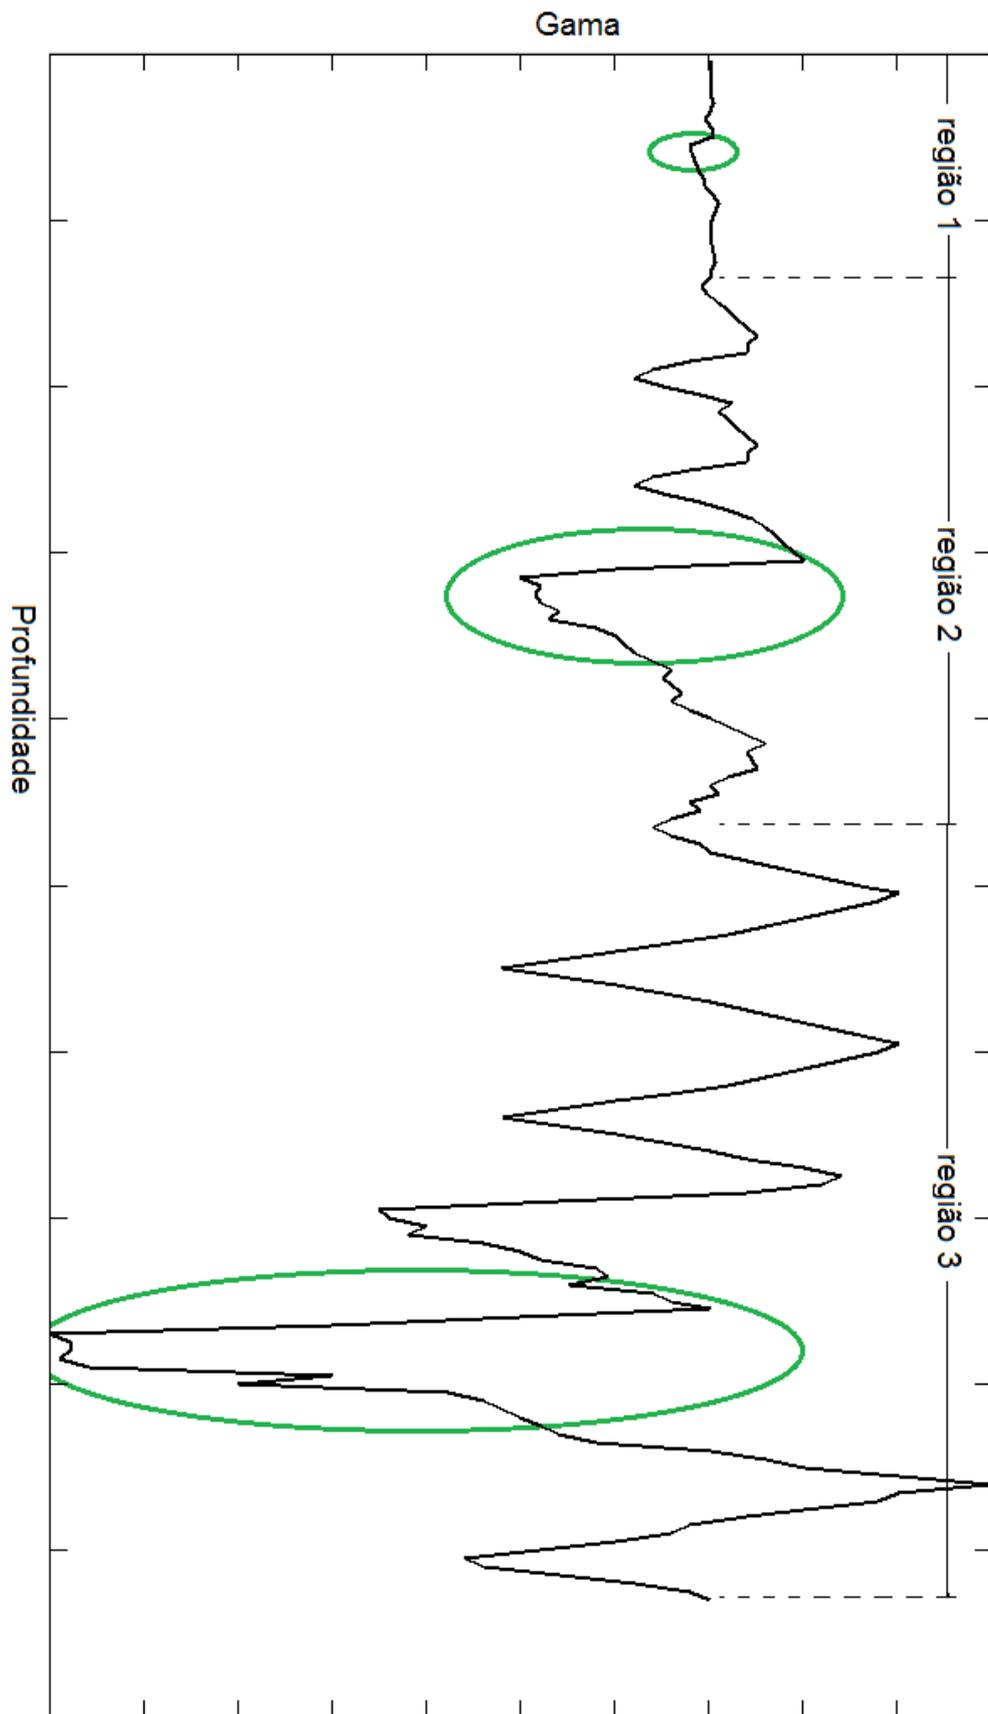


Figura 4.5: Quedas bruscas em regiões com diferentes amplitudes do valor gama

Essas abordagens sofrem de problemas comuns. Apresentam bons resultados em parte, mas ou apresentam excesso de falsos positivos, ou então negligenciam alguns resultados que deveriam ser considerados. Além disso é difícil identificar, por exemplo, o que seria um longo período para o valor gama permanecer abaixo da média para considerar que a queda é considerável e isso certamente demandaria uma análise mais aprofundada, o que está fora do escopo deste trabalho. No entanto, utilizar o desvio padrão para identificar uma queda brusca parece algo mais plausível, já que estatisticamente sabemos que um valor acima do desvio padrão representa algo fora do comportamento natural do gráfico e podemos então associar isso a mudanças bruscas.

A abordagem final se de utiliza duas médias móveis do tipo *Lowess* criadas a partir dos valores gama. Uma delas é a média móvel lenta, que serve para dar o comportamento geral do gráfico (mais lenta inclusive que a utilizada na curva de tendências) e a outra é a média móvel rápida, que é muito mais suscetível a pequenas alterações do perfil de raios gama, mas ainda assim se atém à tendência dele servindo como um tipo de filtro passa-baixas.

Utilizando duas médias móveis descritas acima, é feita a verificação de quando a média móvel rápida cruza a média móvel lenta para baixo, assumindo um valor menor (voltando ao investimento na bolsa de valores, isso significa um possível ponto de venda, já que a tendência é que o valor continue caindo, já no nosso escopo significa apenas um tendência de queda no valor gama), assim temos que verificar se essa queda é ou não abrupta. A partir de então se faz a verificação de uma região de tamanho predeterminado, por exemplo de trinta metros em volta do ponto (os quinze metros anteriores e posteriores ao ponto) computando as diferenças entre os valores da média móvel rápida e lenta. Com isso em mãos, é verificado se a distância entre as duas médias naquele ponto é maior que o desvio padrão relativo à região. Caso positivo, podemos marcar aquele ponto como um possível limite de sequência deposicional. Esse valor de trinta metros é um valor adotado em função dos resultados, mas em futuros testes pode-se tentar chegar a um valor melhor, caso ele exista. De modo geral, valores maiores que esse tendem a verificar a média geral do gráfico, ignorando alguns pontos importantes, já valores menores tendem a utilizar uma média muito localizada, causando número excessivo de falsos positivos.

Levando-se em consideração a natureza um tanto difusa das marcações de limites de sequências deposicionais nas quais é possível marcar diferentes pontos sem que tais diferenças sejam consideradas um erro, optou-se por marcar-se no novo algoritmo, ao invés de um ponto apenas, regiões inteiras nas quais seriam aceitáveis delimitações de limites de sequências deposicionais.

A seguir é mostrado, em pseudo-código, o algoritmo descrito acima:

#### **Parâmetros de entrada:**

*Profundidades // Array contendo profundidades do poço.*

*Valor Gama // Array com valor gama para cada ponto do array de  
// profundidades.*

*Tamanho médio de sequências deposicionais // Tamanho médio que se  
// espera para as sequências deposicionais no poço.*

#### **Início do Algoritmo**

*MédiaMóvelLenta = Média Móvel Lowess com janela igual a  
(Tamanho médio de sequências deposicionais/2)\*3;*

```

MédiaMóvelRápida = Média Móvel Lowess com janela igual a
                    (Tamanho médio de sequências deposicionais/2)/3;
// Laço para percorrer todos os pontos.
Para i=1 até i=Tamanho do Array de Valores Gama
    // Se a media movel rápida for menor que a lenta significa
    // que houve uma queda e verificaremos se ela é ou nao
    // brusca.
    Se ( MédiaMóvelRápida < MédiaMóvelLenta)
        desvPadrao = desvio padrão da diferença entre as
                    duas médias móveis na região do ponto i;
        diff = MédiaMóvelLenta[i] - MédiaMóvelRápida[i];
        // Caso a diferença entre as duas médias seja maior
        // que o desvio padrão, significa que houve uma
        // queda brusca.
        Se (desvPadrao < diff)
            Insere ponto i na região de quedas bruscas;
        Fim-Se
    Fim-se
Fim-Para
Marca regiões de quedas bruscas no gráfico;

```

### **Final do Algoritmo**

No capítulo a seguir, serão comentados alguns dos resultados atingidos por esse novo algoritmo.

## 5 VALIDAÇÃO DA PROPOSTA

Para a validação da proposta serão utilizados dois perfis de poços os quais possuem interpretações detalhadas e foram previamente analisados pelo sistema Intelistrata no trabalho de Fiorini (2009), retirados do livro de Van Wagoner et al. (1990):

- *Tenneco Rattlesnake State 2-12*, localizado na região de Book Cliffs, Utah, USA, com aproximadamente 340 metros a partir da profundidade de 820 m.
- *Exxon Production Research Co. Sejo Canyon n° 2*, localizado na mesma região do poço acima, com aproximadamente 360 metros a partir da profundidade de 30m.

Além desses dois perfis de poços ainda serão avaliados resultados em comparação às marcações feitas pelo especialista – levando-se em consideração apenas informações sobre perfis de raios gama – os perfis de poços CA-53, CA-79 e CA-87, cujos dados foram retirados do trabalho de Goldberg (2001).

### 5.1 Comparativo de resultados: Novo algoritmo x Intelistrata

O sistema Intelistrata apresenta na Figura 5.1 sua interpretação em relação ao perfil de poço *Tenneco Rattlesnake State 2-12*, no qual as linhas tracejadas representam os limites de sequências deposicionais marcados pelo especialista e as regiões verdes, as sequências deposicionais inferidas pelo sistema. As demais marcações são referentes a outros elementos que não representam interesse para o estudo em questão. A Figura 5.2 apresenta os resultados alcançados pelo novo algoritmo. As marcações feitas em verde são relativas aos limites de sequências deposicionais. A exemplo da Figura 5.1, as linhas tracejadas representam os limites de sequência deposicionais marcados pelo especialista. Foram feitas marcações corretas pelo novo algoritmo em todos os pontos (860m, 935m e 1042m) e uma marcação sem correspondente pelo especialista (região entre 940m e 960m), já o sistema Intelistrata apresenta marcações próximas às ideais para as regiões 935m-1042m e 1042m-1160m e ainda conta com três tentativas sem correspondente pelo especialista de marcações dentro dessas duas mesmas regiões.

A Figura 5.3 representa a interpretação do sistema Intelistrata em relação ao perfil de poço *Sejo Canyon n° 2*. Da mesma forma que na Figura 5.1, as linhas tracejadas referem-se às delimitações de sequências deposicionais feitas pelo especialista, enquanto as regiões verdes demonstram a inferência de tais sequências deposicionais feitas pelo sistema e as demais demarcações não demonstram interesse para o caso. A figura 5.4 apresenta os resultados do novo algoritmo para o mesmo poço. As marcações feitas em verde são relativas aos limites de sequências deposicionais. A exemplo da

Figura 5.3, as linhas tracejadas representam os limites de sequências deposicionais marcados pelo especialista. Foram feitas marcações corretas pelo novo algoritmo em todos os pontos (80m, 215m e 345m) e uma marcação sem correspondente pelo especialista (região entre 90m e 110m), já o sistema Intelistrata apresenta marcações próximas às ideais para as regiões 80m-215m e 215m-345m e ainda conta com duas marcações sem correspondente pelo especialista nas regiões de 150m-215m e 230m-375m.

Como se pode observar, o novo algoritmo apresenta maior quantidade de acertos e menor incidência de falsos positivos que o sistema Intelistrata apresentava originalmente. Traduzindo em números, o novo algoritmo faz 4 delimitações nos dois casos, com acerto em todas as 3 marcações dos dois poços e um falso positivo em cada, uma aproveitamento de 100% de acertos em relação às marcações de limites de sequências deposicionais e acerto de 75% das marcações feitas. Já o sistema Intelistrata possui 5 marcações para o poço *Tenneco Rattlesnake State 2-12*, acertando aproximadamente 2 resultados (interpretações B2 e B4 da Figura 5.1) e desperdiçando três. Para o poço *Sego Canyon n° 2* são realizadas 4 marcações de limites de sequência deposicionais, podendo-se considerar que há acerto nas interpretações B1 e B3 da Figura 5.3 e desperdício de 2 marcações. Isso resulta, respectivamente, em aproximadamente 66% de acertos em relação às marcações de limites de sequências deposicionais e acerto de 40% das marcações feitas para o primeiro poço e 66% de acertos em relação às marcações de limites de sequências deposicionais e acerto de 50% das marcações feitas para o segundo poço, dados que dão força ao novo algoritmo aqui apresentado.

Na próxima seção serão apresentados poços não utilizados na validação do sistema Intelistrata no trabalho de Fiorini (2009).

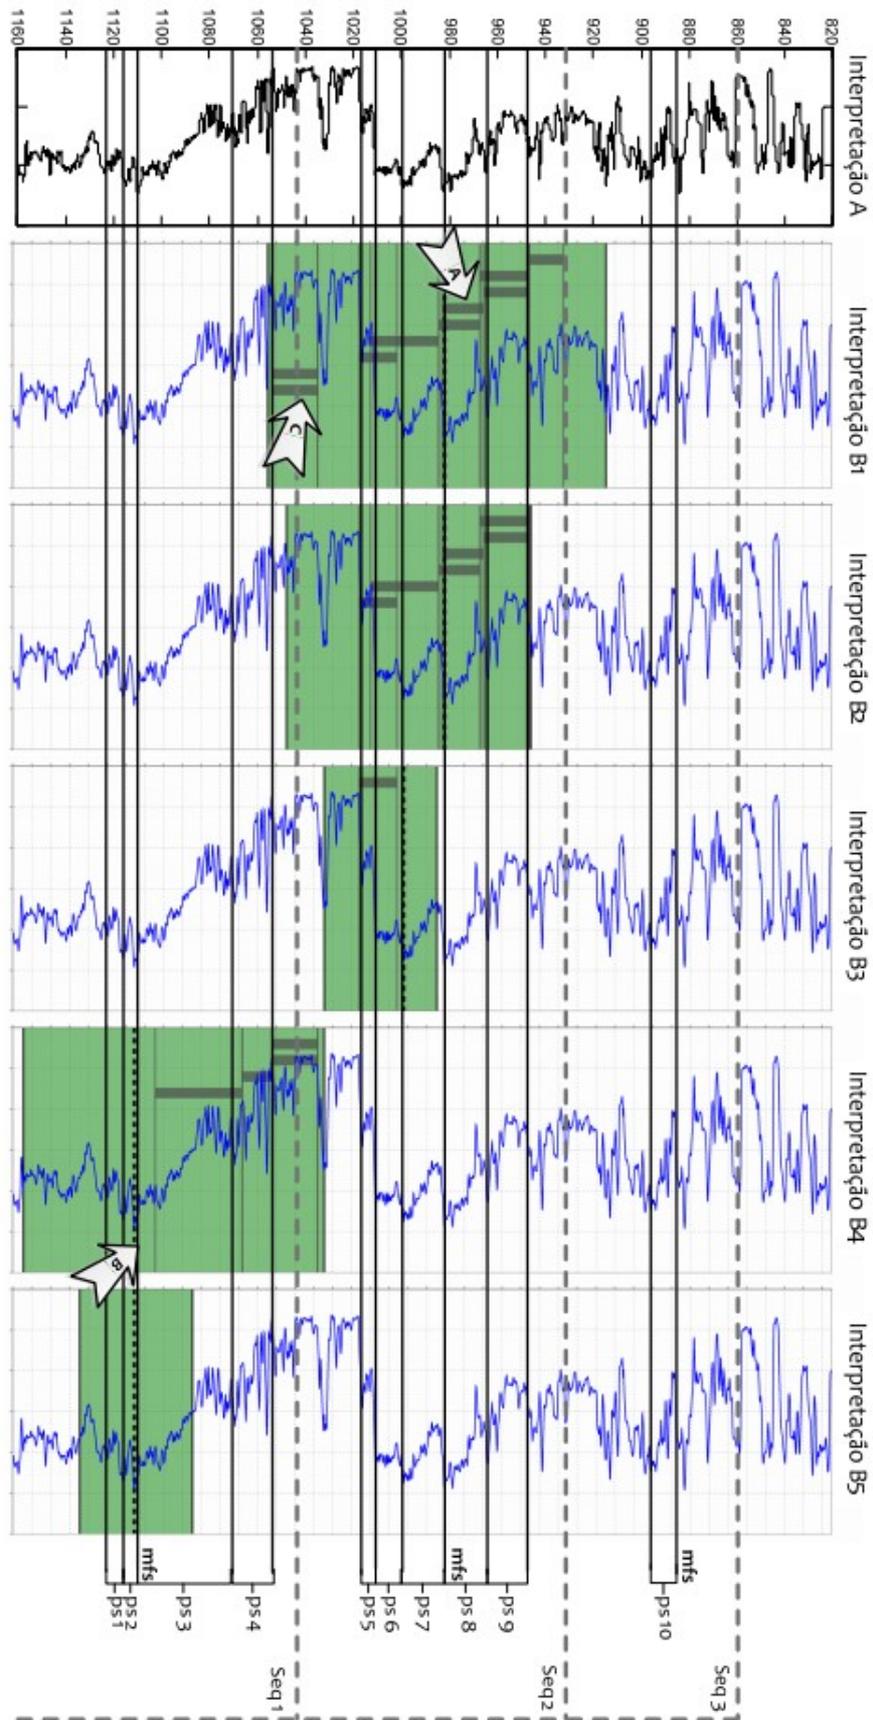


Figura 5.1: Comparação das interpretações do especialista e do sistema Intelistrata para o perfil de poço *Tenneco Rattlesnake State 2-12* (FIORINI, S. R., 2009)

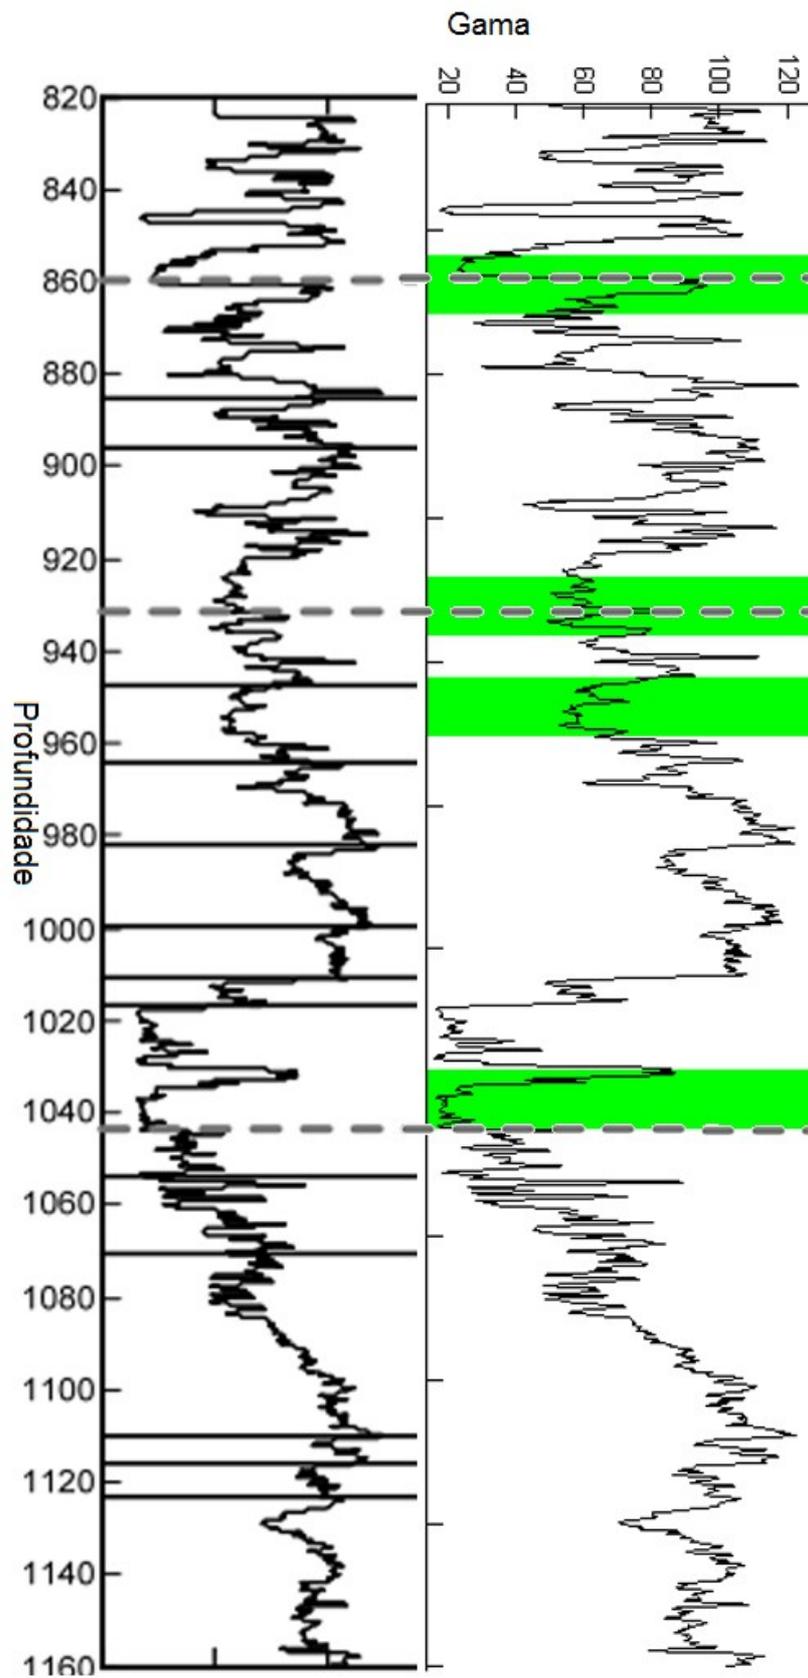


Figura 5.2: Interpretação do perfil de poço *Tenneco Rattlesnake State 2-12* pelo novo algoritmo.

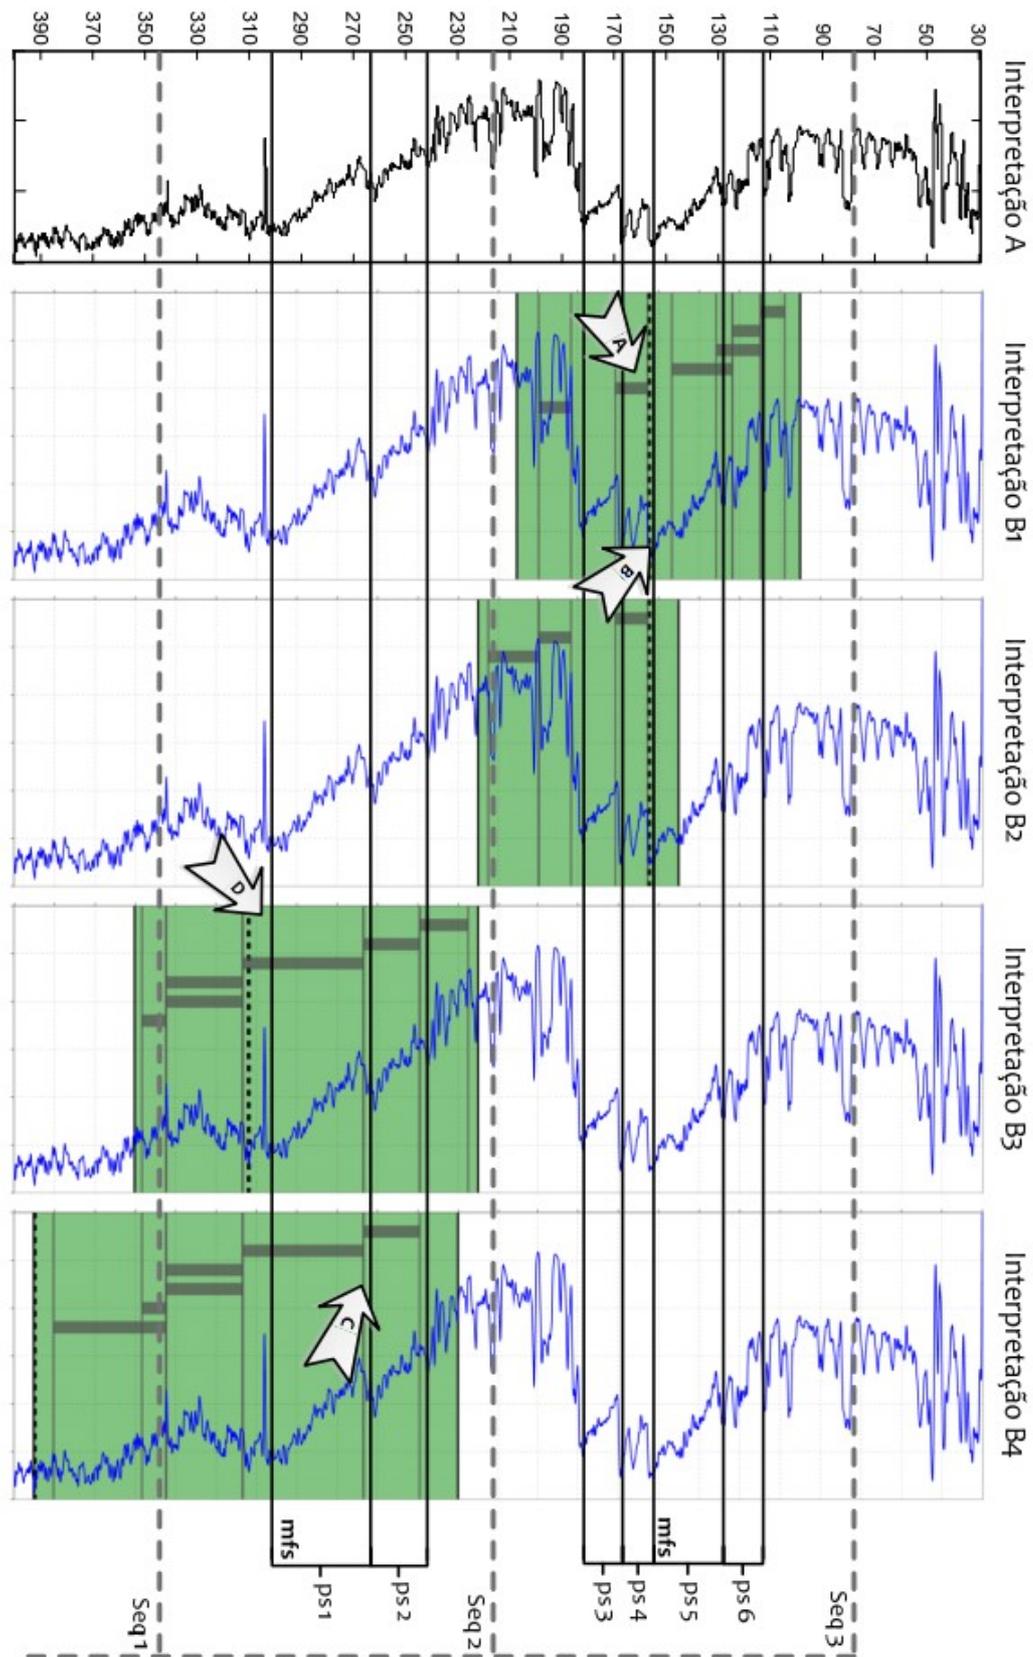


Figura 5.3: Comparação das interpretações do especialista e sistema Intelistrata para o perfil de poço *Exxon Production Research Co. Sejo Canyon n° 2* (FIORINI, S. R., 2009)

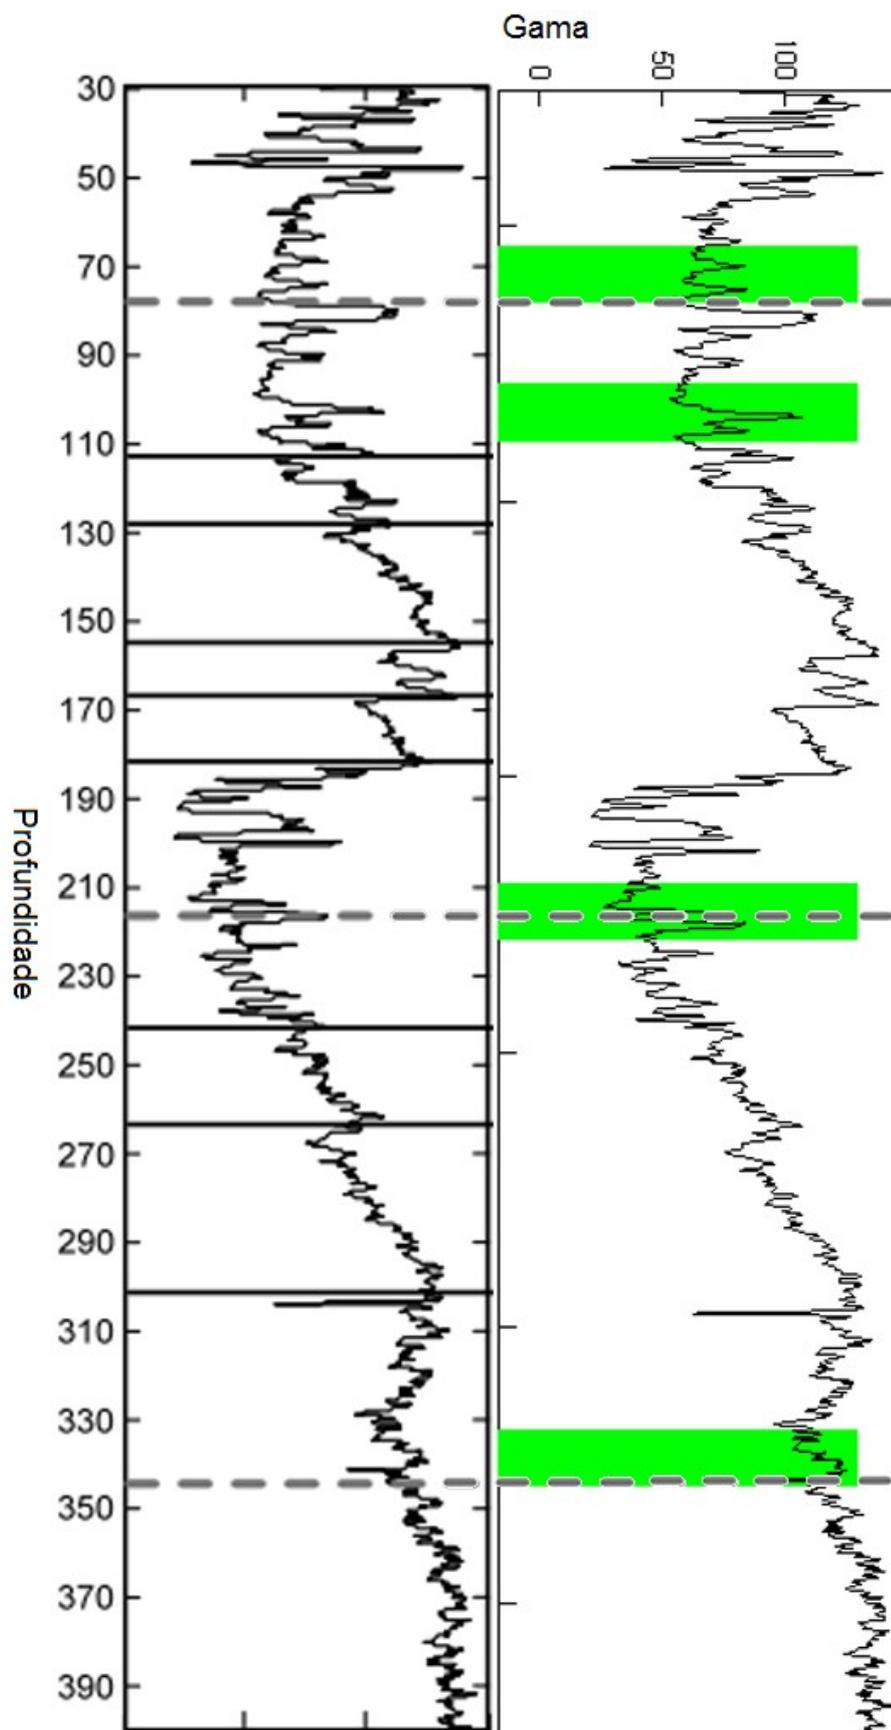


Figura 5.4: Interpretação do perfil de poço *Exxon Production Research Co. Sejo Canyon n° 2* pelo novo algoritmo.

## 5.2 Testes em novos perfis de poços

Para os testes realizados com os perfis de poços CA-53, CA-79 e CA-87, retirados do trabalho de Goldberg (2001) foram comparados os resultados do novo algoritmo com as interpretações contidas na fonte e também foram analisadas opiniões de especialistas. Foram utilizados como tamanho médio de sequência deposicional 100m, 200m e 120m para os poços CA-53, CA-79 e CA-87, respectivamente. É importante lembrar que este trabalho apenas considera perfis de raios gama, enquanto as interpretações contidas no trabalho de Goldberg (2001) estão repletas de outras informações, como curva de resistividade e informações litológicas.

Como pode ser visto nas Figuras 5.5, 5.6 e 5.7, as marcações feitas em verde são relativas às demarcações dos limites de sequências deposicionais feitas pelo novo algoritmo. As linhas vermelhas indicam os limites de sequências deposicionais apontados em (GOLDBERG, K., 2001). É possível observar que algumas marcações feitas pelo novo algoritmo coincidem com as marcações encontradas na fonte e outras apresentam uma aproximação muito satisfatória. Para ilustrar tal afirmação, verifica-se que quando as marcações não coincidem, mas apresentam-se próximas, a diferença entre elas não ultrapassa 4% do tamanho do poço em questão. Ainda foram apresentadas esporádicas marcações que não apresentam representação no novo algoritmo, como por exemplo a marcação próxima à profundidade de 200 metros do poço CA-79 na Figura 5.6, ou mesmo marcações feitas pelo novo algoritmo que não possuem representação no trabalho de Goldberg, como as regiões próximas a 100m e 350m do poço CA-87.

É importante frisar que os geólogos especialistas tiveram dificuldade em marcar os limites de sequência deposicionais nesses perfis sem o auxílio de outras informações (como dados de testemunho e, principalmente, correlação entre poços). Isso não permitiu que fosse feita uma análise a exemplo da adotada na seção 5.1, adotando-se então, como gabarito uma interpretação de (GOLDBERG, K., 2001), cuja interpretação levou em conta não somente o perfil gama. Isso aumenta a credibilidade da abordagem para o novo algoritmo aqui exibida e afirma seu valor como ferramenta de auxílio aos especialistas da área.

A tabela 5.1 mostra os limites de sequência deposicionais marcados em (GOLDBERG, K., 2001) relacionados aos limites de sequências deposicionais mais próximos marcados pelo novo algoritmo e seus respectivos erros, como pode ser observado nas Figuras 5.5, 5.6 e 5.7.

Tabela 5.1: Resultados do novo algoritmo

<b>CA53 – Aproximadamente 642m</b>		
<b>Limite de Sequência Deposicional Marcado pelo Especialista</b>	<b>Limite de Sequência Deposicional Marcado pelo Algoritmo</b>	<b>Erro</b>
136m	114m	3,50%
192m	187m	0,07%
319m	310m	1,50%

394m	Correto	0,00%
498m	483m	2,30%
547m	Correto	0.00%

**CA79 – Aproximadamente 900m**

<b>Limite de Sequência Deposicional Marcado pelo Especialista</b>	<b>Limite de Sequência Deposicional Marcado pelo Algoritmo</b>	<b>Erro</b>
75m	Correto	0,00%
165m	Não Possui	100,00%
343m	325m	2.00%
595m	583m	1,30%
720m	716m	0,04%
790m	Correto	0,00%
890m	Correto	0,00%

**CA87 – Aproximadamente 655m**

<b>Limite de Sequência Deposicional Marcado pelo Especialista</b>	<b>Limite de Sequência Deposicional Marcado pelo Algoritmo</b>	<b>Erro</b>
116m	132m	0,24%
185m	198m	0,19%
308m	292m	0,24%
442m	Correto	0,00%
551m	545m	0,09%
587m	595m	0,12%

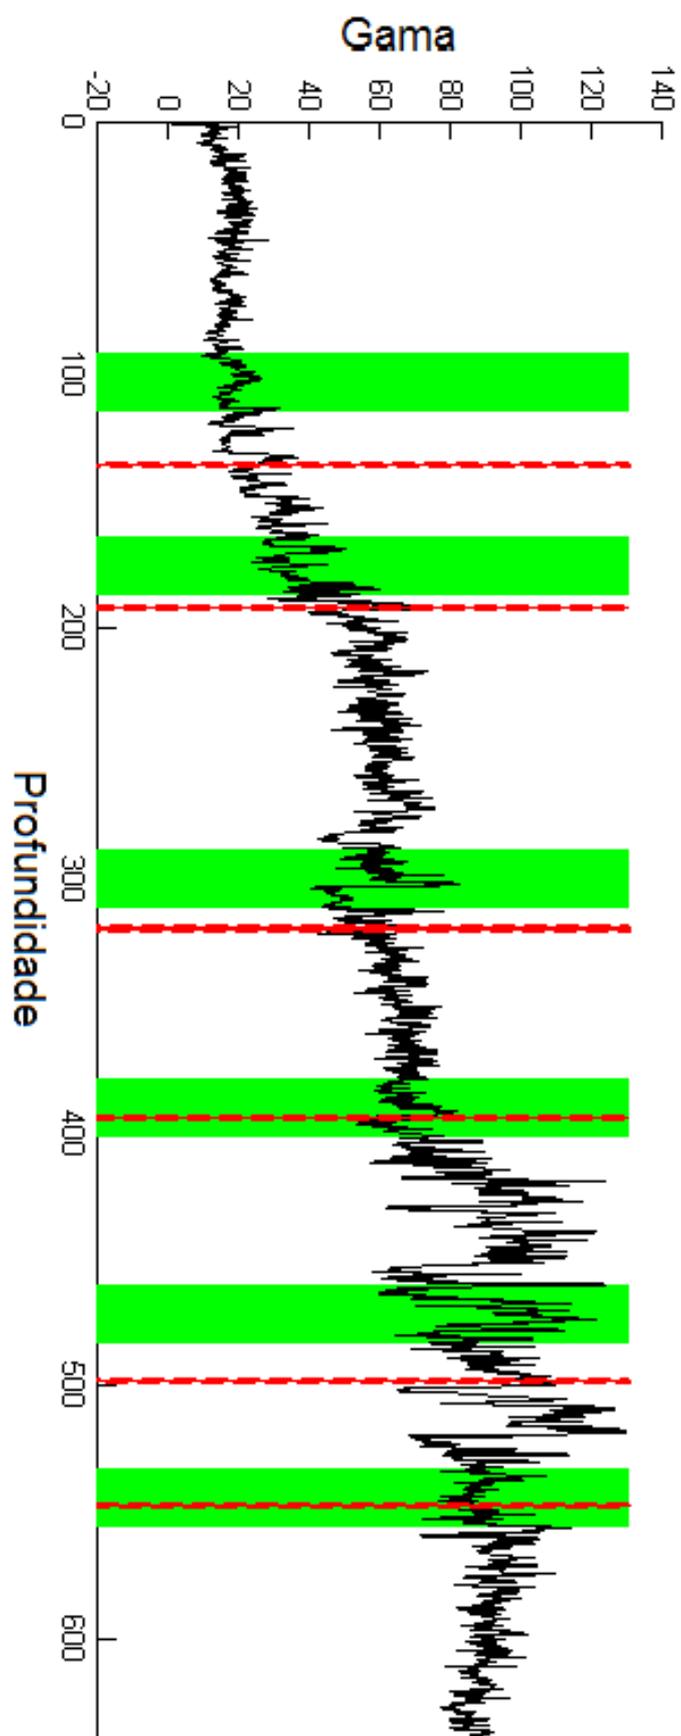


Figura 5.5: Interpretação do perfil de poço CA-53 pelo novo algoritmo.

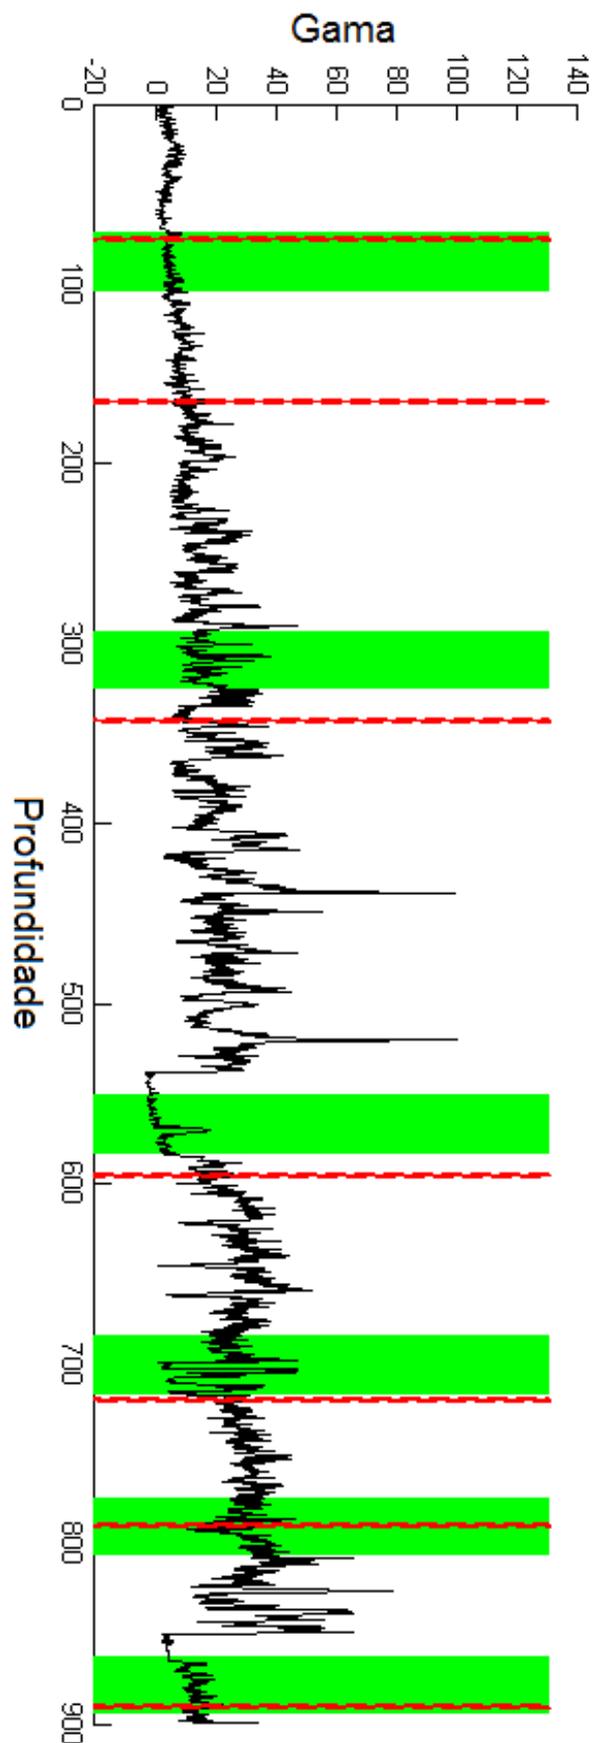


Figura 5.6: Interpretação do perfil de poço CA-79 pelo novo algoritmo.

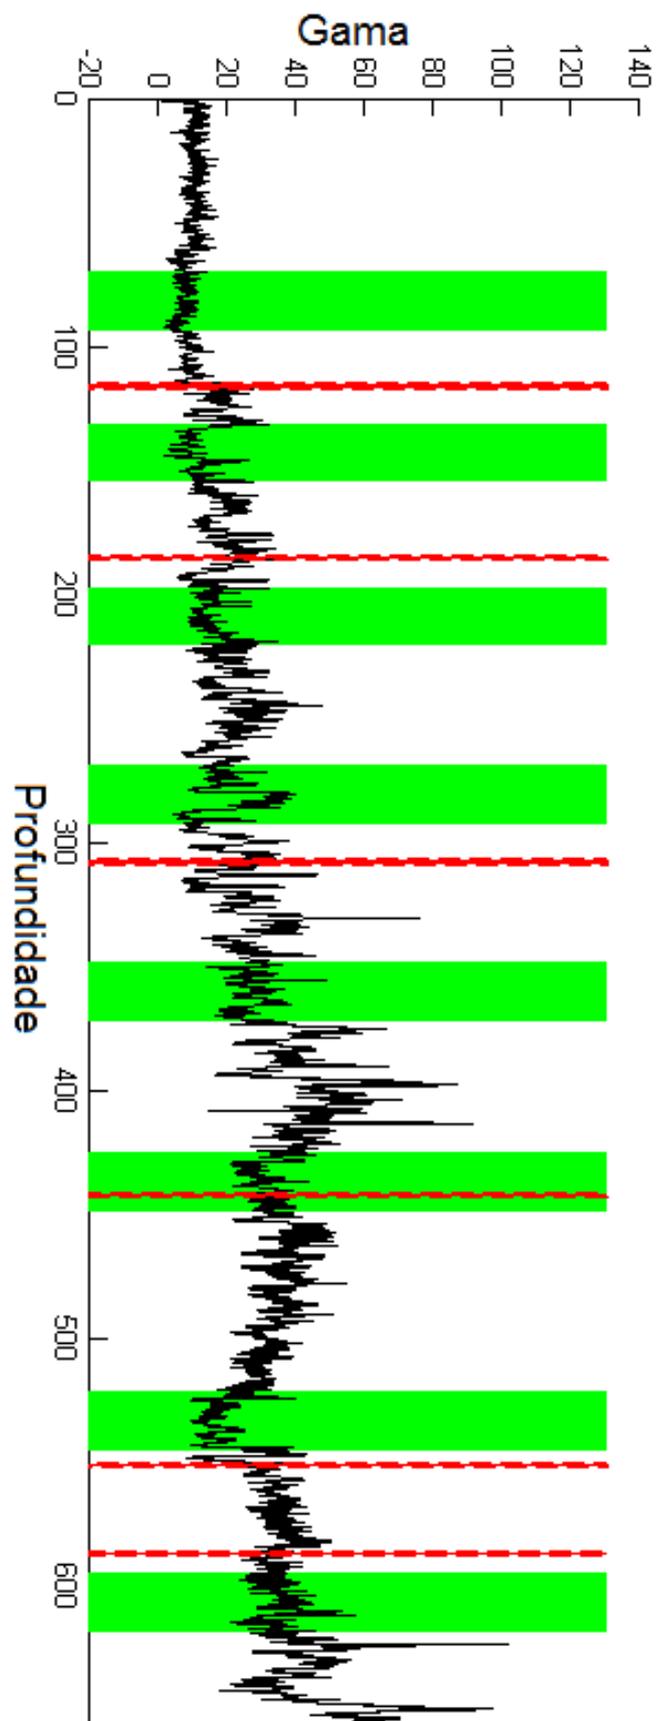


Figura 5.7: Interpretação do perfil de poço CA-87 pelo novo algoritmo.

## 6 CONCLUSÃO

A tarefa de tentar entender e reproduzir os processos cognitivos por trás da visão humana proporciona diversos desafios de pesquisa há anos. Em particular, a interpretação semântica de imagens oferece grandes desafios. Este trabalho tenta buscar complementar a solução de um problema específico de interpretação semântica aplicado na área de Geologia.

Ao longo deste trabalho é proposto um novo algoritmo para o componente de processamento de sinal do sistema baseado no framework S-Chart, chamado Intelistrata. Esse novo algoritmo busca, com sucesso, aprimorar o método de demarcação de limites de sequências deposicionais para posterior interpretação semântica pelos demais componentes do sistema.

O algoritmo proposto neste trabalho teve ganhos tanto em qualidade quanto eficiência nas demarcações de limites de sequências deposicionais, tendo para as duas comparações feitas com o componente de processamento de sinal original do sistema Intelistrata acerto de 100%, contra 66% e eficiência de marcações de 75% contra 40% e 50% do sistema original. Ainda teve boa aproximação de marcações em outros perfis de poços, nas quais seus erros quando não houve marcação precisa em relação à do gabarito não ultrapassaram 4% do tamanho dos poços.

### 6.1 Trabalhos Futuros

Para a detecção de parassequências e superfícies de máxima inundação ainda é possível seguir a mesma abordagem proposta para o novo algoritmo no capítulo 4, utilizando para parassequências exatamente a lógica oposta à detecção de sequências, uma vez que sequências deposicionais são detectadas através de quedas bruscas no valor do gama, enquanto parassequências são detectadas por subidas bruscas, segundo o especialista.

Quanto ao sistema Intelistrata é interessante ampliar os tipos de perfis analisados para se chegar a um resultado mais próximo do real, uma vez que a simples análise de perfis de raios gama sem contar com outros dados pode limitar muito a correteza dos resultados.

## REFERÊNCIAS

- Baader, F., D. Calvanese, D. L. McGuinness, D. Nardi e P. F. Patel-Schneider, Eds. The description logic handbook: theory, implementation, and applications: Cambridge University Press, p.545ed. 2003.
- Baader, F. e R. Kuesters. Matching in Description Logics with Existential Restrictions. 1999
- Ballard, D. H. e C. M. Brown. Computer vision. Englewood Cliffs, N.J.: Prentice-Hall. 1982. xx, 523 p., [2] leaves of plates p.
- Birnbaum, L., M. Brand e P. Cooper. Looking for trouble: Using causal semantics to direct focus of attention. Fourth International Conference on Computer Vision, 1993., 1993. 49-56 p.
- Catuneanu, O. Principles of sequence stratigraphy. Amsterdam ; Boston: Elsevier. 2006. ix, 375 p. p.
- Chandrasekaran, B., J. R. Josephson e V. R. Benjamins. What Are Ontologies, and Why Do We Need Them? IEEE Intelligent systems: 7 p. 1999.
- Chella, A., M. Frixione e S. Gaglio. A cognitive architecture for artificial vision. Artif. Intell., v.89, n.1-2, p.73-111. 1997.
- Chella, A., M. Frixione e S. Gaglio. Conceptual Spaces for Computer Vision Representations. Artif. Intell. Rev., v.16, n.2, p.137-152. 2001.
- Chella, A., M. Frixione e S. Gaglio. A cognitive architecture for robot self-consciousness. Artif. Intell. Med., v.44, n.2, p.147-154. 2008.
- Chella, A. e S. Gaglio. A cognitive approach to robot self-consciousness. AI and Consciousness: Theoretical Foundations and ... 2007.
- Cohn, A. G. e S. M. Hazarika. Qualitative Spatial Representation and Reasoning: An Overview. Fundam. Inf., v.46, n.1-2, p.1-29. 2001.
- Cohn, A. G., D. R. Magee, A. Galata, D. C. Hogg e S. M. Hazarika. Towards an Architecture for Cognitive Vision Using Qualitative Spatio-temporal Representations and Abduction In: (Ed.). Spatial Cognition III: Springer Berlin / Heidelberg, v. Volume 2685/2003, 2003. Towards an Architecture for Cognitive Vision Using Qualitative Spatio-temporal Representations and Abduction p.1034
- Crubézy, M., M. Marcos e S. Moisan. Experiments in Building Program Supervision Engines from Reusable Components. 3th European Conference on Artificial Intelligence Workshop on Applications of Ontologies and Problem-Solving Methods, 1998. p.
- Fiorini, S. R. S-Chart: Um Arcabouço para Interpretação Visual de Gráficos. Computer Science, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009. 122 p.

- Gärdenfors, P. *Conceptual Spaces: The Geometry of Thought*: MIT Press. 2004. 320 p.
- Goldberg, K. *The paleoclimatic evolution of the Permian in the Parana Basin in southern Brazil*. University of Chicago, 2001. 267 p.
- Gómez-Pérez, A., M. Fernández-López e O. Corcho. *Ontological engineering : with examples from the areas of knowledge management, e-commerce and the semantic Web*. London: Springer. 2004. xii, 403 p.
- Gruber, T. R. *Toward principles for the design of ontologies used for knowledge sharing*. *Int. J. Hum.-Comput. Stud.*, v.43, n.5-6, p.907-928. 1995.
- Haag, M., W. Theilmann, K. Schäfer e H.-H. Nagel. *Integration of Image Sequence Evaluation and Fuzzy Metric Temporal Logic Programming*. *Proceedings of the 21st Annual German Conference on Artificial Intelligence: Advances in Artificial Intelligence*: Springer-Verlag: 301-312 p. 1997.
- Haarslev, V. e R. Möller. *RACER System Description*. *Proceedings of the First International Joint Conference on Automated Reasoning*: Springer-Verlag: 701-706 p. 2001.
- Harnad, S. *The symbol grounding problem*. *Phys. D*, v.42, n.1-3, p.335-346. 1990.
- Hotz, L. e B. Neumann. *Scene Interpretation as a Configuration Task*. *Künstliche Intelligenz*, v.3, p.56-65. 2005.
- Hotz, L., B. Neumann e K. Terzic. *High-Level Expectations for Low-Level Image Processing*. *Proceedings of the 31st annual German conference on Advances in Artificial Intelligence*. Kaiserslautern, Germany: Springer-Verlag: 87-94 p. 2008.
- Hudelot, C. *Towards a Cognitive Vision Platform for Semantic Image Interpretation; Application to the Recognition of Biological Organisms*. Université de Nice - Sophia Antipolis UFR Sciences, 2005. 280 p.
- Hudelot, C., N. Maillot e M. Thonnat. *Symbol Grounding for Semantic Image Interpretation: From Image Data to Semantics*. *Tenth IEEE International Conference on Computer Vision*, p.8. 2004.
- Kaufman, P. J. *Trading systems and methods*. New York: John Wiley. 1998. xv, 703 p.
- Kreutzmann, A., K. Terzić e B. Neumann. *Context-aware classification for incremental scene interpretation*. *Proceedings of the Workshop on Use of Context in Vision Processing*. Boston, Massachusetts: ACM: 1-6 p. 2009.
- Lorenzatti, A. *Análise de modelos para a representação de conhecimento visual*. p.18. 2008.
- Maillot, N., M. Thonnat e C. Hudelot. *Ontology Based Object Learning and Recognition: Application to Image Retrieval*. *Proceedings of the 16th IEEE International Conference on Tools with Artificial Intelligence*: IEEE Computer Society: 620-625 p. 2004.

Nagel, H.-H. From Video to Language-A Detour via Logic vs. Jumping to Conclusions. Proceedings of the Integration of Speech and Image Understanding: IEEE Computer Society: 79 p. 1999.

Neumann, B. Description of Time-Varying Scenes. Lawrence Erlbaum, n.Semantic Structures, p.167-206. 1989.

Neumann, B. e R. Möller. On Scene Interpretation with Description Logics In: (Ed.). Cognitive Vision Systems: Springer Berlin / Heidelberg, v.Volume 3948/2006, 2006. On Scene Interpretation with Description Logics p.247-275

PETR Disponível em: <<http://www.petrobras.com.br/rs2009/pt/relatorio-de-sustentabilidade/resultados-e-contribuicoes-para-a-sociedade/resultados-economico-financeiros/investimentos/>> Acesso em nov. 2010.

Posamentier, H.W., Jervey, M.T. e Vail, P.R. 1988. Eustatic controls on clastic deposition I – conceptual framework. In: WILGUS, C.K.; HASTINGS, B.S.; KENDALL, C.G.; ST. C.; POSAMENTIER, H.W.; ROSS, C.A. & VAN WAGONER, J.C. (Eds.) 1988. Sea-level changes: an integrated approach. Society of Economic Paleontologists and Mineralogists Special Publication, 42, 407 p.

Raicu, D. S., E. Varutbangkul, J. D. Furst e S. G. A. Iii. Modelling semantics from image data: opportunities from LIDC. International Journal of Biomedical Engineering and Technology 2010 v.3, p.83 - 113. 2010.

Randell, D. e M. Witkowski. Abductive Visual Perception with Feature Clouds. 2006.

Reading, H. G. Sedimentary environments : processes, facies, and stratigraphy. Cambridge, Mass: Blackwell Science. 1996. xiv, 688 p.

Rimey, R. D. Control of Selective Perception using Bayes Nets and Decision Theory. University of Rochester. 1993

Shanahan, M. A Logical Account of Perception Incorporating Feedback and Expectation. Knowledge Representation Conference, 2002. 3-13 p.

Shanahan, M. e D. A. Randell. A Logic-Based Formulation of Active Visual Perception. Principles of Knowledge Representation and Reasoning: Proceedings of the Ninth International Conference (KR2004). Whistler, Canada, June 2-5, 2004, 2004. 64-72 p.

Stock, O. Spatial and Temporal Reasoning: Kluwer Academic Publishers. 1997. 394 p.

Vail, P. R., Mitchum JR., R. M., Todd, R. G., Widmier, J. M., Thompson, S., III, Sangree, J. B., Bubb, J. N., Hatlelid, W. G. Seismic stratigraphy and global changes of sea level. In: PAYTON, C. E. (Ed.) Seismic stratigraphy - applications to hydrocarbon exploration. Tulsa: American Association of Petroleum Geologists, 1977a. p. 49-212. (American Association of Petroleum Geologists. Memoir, 26).

Van Wagoner, J.C.; Mitchum, R.M.; Campion, K.M. & Rahmanian, V.D. 1990. Siliciclastic sequence stratigraphy in well logs, cores, and outcrops: concepts for high resolution correlation of time and facies. American Association of Petroleum Geologists Methods in Exploration Series, No 7.

Vila, L. A survey on temporal reasoning in artificial intelligence. *AI Commun.*, v.7, n.1, p.4-28. 1994.

Xia, L., F. Yiren, D. Shaogui e W. Tongshan. Automatic demarcation of sequence stratigraphy using the method of well logging multiscale data fusion. Online English edition of the Chinese language journal, v. Volume 36, n. Issue 2, April 2009, p.7. 2009.