

**MODELAGEM  
COMPUTACIONAL  
DE CONHECIMENTO**

Dissertação de Mestrado

## Estimação do Erro em Redes de Sensores sem Fios

José Alencar-Neto  
jalencar@gmail.com

Orientador:  
Prof. Dr. Alejandro C. Frery

Maceió, Maio de 2008

José Alencar-Neto

## Estimação do Erro em Redes de Sensores sem Fios

Dissertação apresentada como requisito parcial para obtenção do grau de Mestre pelo Curso de Mestrado em Modelagem Computacional de Conhecimento da Universidade Federal de Alagoas.

Orientador:

Prof. Dr. Alejandro C. Frery

**Catálogo na fonte**  
**Universidade Federal de Alagoas**  
**Biblioteca Central**  
**Divisão de Tratamento Técnico**  
**Bibliotecária Responsável: Maria Auxiliadora G. da Cunha**

F311e      Feitosa Neto, José Alencar.  
              Estimação do erro em redes de sensores sem fios / José Alencar Feitosa Neto.  
              – Maceió, 2008  
              viii, 104 f. : il.

Orientador: Alejandro C. Frery.  
Dissertação (mestrado em Modelagem Computacional de Conhecimento) –  
Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2008.

Bibliografia: f. 100-103.

1. Monte Carlo, Método de. 2. Modelagem. 3. Simulação. 4. Integração de dados de múltiplos sensores. 5. Erro. 6. Desempenho. 7. Reconstrução. 8. Projetos de sistemas. I. Título.

CDU: 004.75:519.24



UNIVERSIDADE FEDERAL DE ALAGOAS – UFAL  
**Programa Multidisciplinar de Pós-Graduação em  
Modelagem Computacional de Conhecimento**  
Avenida Lourival Melo Mota, Km 14, Bloco 09, Cidade Universitária  
CEP: 57.072-900 – Maceió – AL – Brasil  
Telefone: (082) 3214-1364



Dissertação de Mestrado em Modelagem Computacional de Conhecimento, intitulada “Estimação do Erro em Redes de Sensores sem Fios”, apresentada por José Alencar Feitosa Neto, como requisito parcial para a obtenção do grau de Mestre em Modelagem Computacional de Conhecimento, perante a seguinte Comissão Examinadora:

Prof. Dr. Alejandro Cesar Frery – Orientador  
Instituto de Computação – UFAL

Prof. Dr. Antonio Alfredo Ferreira Loureiro – Membro Externo  
Departamento de Ciência da Computação – UFMG

Prof. Dr. Marcio Nunes de Miranda – Membro Interno  
Instituto de Computação – UFAL

# Agradecimentos

Acima de tudo agradeço a Deus Pai, Deus Filho e Deus Espírito Santo porque tudo a mim concede.

Agradeço com todo meu amor a minha esposa Itala C. de Alencar pelo apoio e carinho em tantas noites de trabalho árduo.

Agradeço a meus pais Ossian e Danúbia Alencar pela educação e dedicação prestadas por toda a minha formação.

Agradeço ao amigo Heitor pela ajuda e troca de experiências.

Agradeço aos colegas do nosso recente e promissor Grupo de Redes de Sensores da Universidade Federal de Alagoas.

Agradeço aos colegas de trabalho pela paciência e compreensão nesta etapa da minha vida acadêmica.

# Resumo

Apresentamos as redes de sensores sem fios no contexto da aquisição de informação, e propomos um modelo genérico baseado nos processos de amostragem e de reconstrução de sinais. Utilizando esse modelo, definimos uma medida de desempenho do funcionamento das redes através do erro de reconstrução do sinal. Dada a complexidade analítica de se calcular esse erro em diferentes cenários, propomos e implementamos uma experiência Monte Carlo que permite avaliar quantitativamente a contribuição de diversos fatores no desempenho de uma rede de sensores sem fios. Esses fatores são (i) a distribuição espacial dos sensores, (ii) a granularidade do fenômeno sob observação, (iii) a forma em que os sensores amostram o fenômeno (funções características constantes sobre células de Voronoi e sobre círculos), (iv) as características de comunicação entre os sensores (por vizinhança entre células de Voronoi e pelo raio de comunicação), (v) os algoritmos de clusterização e agregação (LEACH e SKATER), e (vi) as técnicas de reconstrução (por Voronoi e por Kriging). Os resultados obtidos permitem concluir que todos esses fatores influem significativamente no desempenho de uma rede de sensores sem fios e, pela metodologia de trabalho, foi possível medir essa influência em todos os cenários considerados.

# Abstract

Wireless Sensor Networks (WSNs) are presented in the context of information acquisition, and we propose a generic model based on the processes of signal sampling and reconstruction. We then define a measure of performance using the error when reconstructing the signal. The analytical assessment of this measure in a variety of scenarios is unfeasible, so we propose and implement a Monte Carlo experiment for estimating the contribution of six factors on the performance of a WSN, namely: (i) the spatial distribution of sensors, (ii) the granularity of the phenomenon being monitored, (iii) the way in which sensors sample the phenomenon (constant characteristic functions defined on Voronoi cells or on circles), (iv) the communication between sensors (either among neighboring Voronoi cells or among sensors within a range), (v) the clustering and aggregation algorithms (LEACH and SKATER), and (vi) the reconstruction techniques (by Voronoi cells and by Kriging). We conclude that all these factors have significative influence on the performance of a WSN, and we are able to quantitatively assess this influence.

# Sumário

<b>1</b>	<b>Introdução</b>	<b>1</b>
<b>2</b>	<b>Definições</b>	<b>4</b>
2.1	Notação e definições	4
2.2	Redes de sensores sem fio	5
2.2.1	Representação de uma rede de sensores sem fio	5
2.2.2	Energia e ciclo de vida da WSN	6
2.3	Consulta, processamento e aquisição de informação em WSN	7
2.4	Processos Estocásticos	8
2.4.1	Campos aleatórios	10
2.4.2	Processos pontuais	11
<b>3</b>	<b>Metodologia</b>	<b>15</b>
3.1	Motivação	15
3.2	Proposta	16
3.3	Modelos	17
3.3.1	Região monitorada	17
3.3.2	Fenômeno em observação	17
3.3.3	Distribuição dos sensores	18
3.3.4	Sensores	22
3.3.4.1	Situação 1: células de Voronoi como área de percepção	24
3.3.4.2	Situação 2: resposta radial como área de percepção	24
3.3.5	Amostragem	24
3.3.5.1	Amostragem - <i>situação1</i>	25
3.3.5.2	Amostragem - <i>situação2</i>	25
3.3.6	Clusterização	26
3.3.6.1	Clusterização - <i>situação1</i>	26
3.3.6.2	Clusterização - <i>situação2</i>	28
3.3.7	Agregação	29
3.3.8	Reconstrução	31
3.3.8.1	Reconstrução a partir da amostragem individual	31
3.3.8.2	Reconstrução a partir da clusterização/agregação	33
3.4	Flexibilidade do Modelo	37
3.4.1	Região monitorada e fenômeno em observação	37
3.4.2	Distribuição dos sensores	38
3.4.3	Sensores	38
3.4.4	Amostragem	38
3.4.5	Clusterização	39
3.4.5.1	Modo <i>interativo</i>	39
3.4.5.2	Modo <i>streaming</i>	39
3.4.6	Agregação	39
3.4.6.1	Modo <i>interativo</i>	39
3.4.6.2	Modo <i>streaming</i>	39
3.4.7	Reconstrução	40
3.5	Estudo Monte Carlo	40
3.6	Detalhes de implementação e execução	40

3.6.1	Plataformas computacionais . . . . .	40
3.6.2	Execução das simulações . . . . .	41
3.6.3	Considerações de implementação . . . . .	42
3.6.3.1	Geração dos dados do fenômeno $f$ . . . . .	42
3.6.3.2	Geração dos dados de distribuição dos sensores . . . . .	42
3.6.3.3	Células de Voronoi . . . . .	42
3.6.3.4	Área de percepção . . . . .	42
3.6.3.5	Processos atrativos e região alvo . . . . .	42
3.6.3.6	Raio de comunicação $r_c$ . . . . .	43
3.6.3.7	Número de <i>clusters</i> . . . . .	43
3.6.3.8	LEACH e a formação dos <i>clusters</i> . . . . .	43
3.6.3.9	LEACH e a escolha dos <i>clusters heads</i> . . . . .	43
3.6.3.10	SKATER e a formação dos <i>clusters</i> . . . . .	44
3.6.3.11	Estação base . . . . .	44
3.6.3.12	Reconstrução por Voronoi . . . . .	44
3.6.3.13	Modelo do Kriging adotado . . . . .	44
3.6.4	Ajustes de implementações . . . . .	44
3.6.4.1	Comparando a <i>situação1</i> e <i>situação2</i> quanto à reconstrução a partir do SKATER . . . . .	44
<b>4</b>	<b>Resultados</b>	<b>47</b>
4.1	Execução das Simulações . . . . .	47
4.2	Descrições das Avaliações das Estimções do Erro . . . . .	47
4.3	Medidas de Avaliação do Erro . . . . .	49
4.4	Legendas . . . . .	49
4.5	Resultados e Avaliações para a <i>Situação1</i> . . . . .	50
4.6	Resultados e Avaliações para a <i>Situação2</i> . . . . .	66
4.7	Confrontação entre a <i>Situação1</i> e a <i>Situação2</i> . . . . .	87
4.8	Resumo dos Resultados . . . . .	94
<b>5</b>	<b>Conclusões</b>	<b>98</b>
	<b>Referências Bibliográficas</b>	<b>100</b>

# Lista de Figuras

2.1	Três processos pontuais Poisson com $\eta = 50$ . . . . .	12
2.2	Processos de Poisson não homogêneos . . . . .	13
2.3	SSI com $n = 50$ . . . . .	14
3.1	Níveis conceituais do trabalho . . . . .	16
3.2	Modelo . . . . .	16
3.3	Floresta monitorada . . . . .	17
3.4	Fenômeno iluminação . . . . .	18
3.5	Distribuição - processo regular . . . . .	19
3.6	Distribuição - processo repulsivo . . . . .	20
3.7	Distribuição - processo repulsivo . . . . .	20
3.8	Distribuição - processo atrativo . . . . .	21
3.9	Distribuição - processo atrativo . . . . .	21
3.10	Distribuição - processo independente . . . . .	22
3.11	Área de percepção - Função característica . . . . .	23
3.12	Área de comunicação - Relação de vizinhança . . . . .	23
3.13	Iluminação e área de percepção . . . . .	25
3.14	Amostragem $\Psi_1$ - Células de Voronoi . . . . .	25
3.15	Amostragem $\Psi_1$ - Resposta radial . . . . .	26
3.16	Clusterização $\Psi_2$ - <i>Situação 1</i> - Protocolo LEACH . . . . .	27
3.17	Clusterização $\Psi_2$ - <i>Situação 1</i> - Protocolo SKATER . . . . .	28
3.18	Clusterização $\Psi_2$ - <i>Situação 2</i> - Protocolo LEACH . . . . .	29
3.19	Clusterização $\Psi_2$ - <i>Situação 2</i> - Protocolo SKATER . . . . .	29
3.20	Clusterização/agregação a partir do LEACH e do SKATER na <i>situação 1</i> . . . . .	30
3.21	Processo de reconstrução a partir da amostragem $\Psi_1$ na <i>situação 1</i> . . . . .	32
3.22	Processo de reconstrução a partir da amostragem $\Psi_1$ na <i>situação 2</i> . . . . .	33
3.23	Processo de reconstrução a partir da clusterização/agregação $\Psi_{3_L}$ na <i>situação 1</i> . . . . .	34
3.24	Reconstrução a partir da clusterização/agregação $\Psi_{3_S}$ na <i>situação 1</i> . . . . .	35
3.25	Reconstrução a partir da clusterização/agregação $\Psi_{3_L}$ na <i>situação 2</i> . . . . .	36
3.26	Reconstrução a partir da clusterização/agregação $\Psi_{3_S}$ na <i>situação 2</i> . . . . .	37
3.27	Plataformas e Ferramentas - Integração . . . . .	41
3.28	Processo Atrativo e região alvo . . . . .	43
3.29	Áreas de Percepção na <i>Situação 1</i> na e <i>Situação 2</i> . . . . .	45
3.30	Áreas de Comunicação na <i>Situação 1</i> na e <i>Situação 2</i> com $r_c = 15$ m . . . . .	46
4.1	Legendas dos Gráficos do Erro variando os Processos Pontuais . . . . .	50
4.2	Legendas dos Gráficos do Erro variando as Escalas . . . . .	50
4.3	Reconstruções $\Psi_4$ a partir de $\Psi_1$ , $\Psi_{3_L}$ e de $\Psi_{3_S}$ - 100 sensores na <i>situação 1</i> . . . . .	51
4.4	Média do erro de Reconstrução por Voronoi a partir de $\Psi_1$ , $\Psi_{3_L}$ e $\Psi_{3_S}$ - <i>Situação 1</i> . . . . .	52
4.5	Variância do erro de Reconstrução por Voronoi a partir de $\Psi_1$ , $\Psi_{3_L}$ e $\Psi_{3_S}$ - <i>Situação 1</i> . . . . .	53
4.6	Média do erro de Reconstrução por Kriging a partir de $\Psi_1$ , $\Psi_{3_L}$ e $\Psi_{3_S}$ - <i>Situação 1</i> . . . . .	54
4.7	Variância do erro de Reconstrução por Kriging a partir de $\Psi_1$ , $\Psi_{3_L}$ e $\Psi_{3_S}$ - <i>Situação 1</i> . . . . .	55
4.8	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_1$ - <i>Situação 1</i> . . . . .	56
4.9	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_1$ na escala $s = 10$ . . . . .	57
4.10	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_L}$ - <i>Situação 1</i> . . . . .	58
4.11	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_{3_L}$ na escala $s = 20$ . . . . .	59

4.12	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_S}$ - <i>Situação1</i> . . .	60
4.13	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_{3_S}$ na escala $s = 20$ . . .	61
4.14	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_{3_S}$ na escala $s = 10$ . . .	62
4.15	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_S}$ - <i>Situação1</i> . . .	63
4.16	Reconstruções $\Psi_{4_V}$ a partir de $\Psi_1$ - 100 sensores na <i>situação1</i> . . . . .	64
4.17	Reconstruções $\Psi_{4_K}$ a partir de $\Psi_1$ - 100 sensores na <i>situação1</i> . . . . .	64
4.18	Reconstruções $\Psi_{4_V}$ a partir de $\Psi_{3_S}$ - 100 sensores na <i>situação1</i> . . . . .	65
4.19	Reconstruções $\Psi_{4_K}$ a partir de $\Psi_{3_S}$ - 100 sensores na <i>situação1</i> . . . . .	65
4.20	Reconstruções $\Psi_{4_V}$ a partir de $\Psi_{3_L}$ - 100 sensores na <i>situação1</i> . . . . .	66
4.21	Reconstruções $\Psi_{4_K}$ a partir de $\Psi_{3_L}$ - 100 sensores na <i>situação1</i> . . . . .	66
4.22	Características de comunicação dos sensores na <i>Situação1</i> e na <i>Situação2</i> . . . . .	67
4.23	Reconstruções $\Psi_4$ a partir de $\Psi_1$ , $\Psi_{3_L}$ e de $\Psi_{3_S}$ - 100 sensores na <i>situação2</i> . . . . .	68
4.24	Média do erro de Reconstrução por Voronoi a partir de $\Psi_1$ , $\Psi_{3_L}$ e $\Psi_{3_S}$ - <i>Situação2</i> . . .	69
4.25	Variância do erro de Reconstrução por Voronoi a partir de $\Psi_1$ , $\Psi_{3_L}$ e $\Psi_{3_S}$ - <i>Situação2</i> . .	70
4.26	Média do erro de Reconstrução por Kriging a partir de $\Psi_1$ , $\Psi_{3_L}$ e $\Psi_{3_S}$ - <i>Situação2</i> . . . .	71
4.27	Variância do erro de Reconstrução por Kriging a partir de $\Psi_1$ , $\Psi_{3_L}$ e $\Psi_{3_S}$ - <i>Situação2</i> . .	72
4.28	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_1$ - <i>Situação2</i> . .	73
4.29	Variância do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_1$ - <i>Situação2</i> . .	74
4.30	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_1$ na escala $s = 20$ <i>Situação2</i>	75
4.31	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_1$ na escala $s = 5$ <i>Situação2</i>	76
4.32	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_L}$ - <i>Situação2</i> . .	77
4.33	Variância do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_L}$ - <i>Situação2</i> . .	78
4.34	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_{3_L}$ na escala $s = 20$ <i>Situação2</i>	79
4.35	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_S}$ - <i>Situação2</i> . .	80
4.36	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_{3_S}$ na escala $s = 20$ <i>Situação2</i>	81
4.37	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_{3_S}$ na escala $s = 5$ <i>Situação2</i>	82
4.38	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_S}$ - <i>Situação2</i> . .	83
4.39	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_S}$ - <i>Situação2</i> com $r_c = 36$ m e com $r_c = 15$ m . . . . .	84
4.40	Raio de Comunicação $r_c$ dos sensores <i>tipo2</i> com $r_c = 36$ m e com $r_c = 15$ m . . . . .	85
4.41	Reconstruções por Voronoi $\Psi_{4_V}$ e por Kriging $\Psi_{4_K}$ a partir de $\Psi_{3_S}$ - processo pontual regular e todas escalas $s$ na <i>Situação2</i> com $r_c = 36$ m e com $r_c = 15$ m . . . . .	86
4.42	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_1$ - <i>Situação1</i> e <i>Situação2</i> . . . . .	88
4.43	Variância do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_1$ - <i>Situação1</i> e <i>Situação2</i> . . . . .	89
4.44	Reconstruções $\Psi_{4_V}$ a partir de $\Psi_1$ - <i>situação1</i> (Sit1) e <i>situação2</i> (Sit2) . . . . .	90
4.45	Reconstruções $\Psi_{4_K}$ a partir de $\Psi_1$ - <i>situação1</i> (Sit1) e <i>situação2</i> (Sit2) . . . . .	91
4.46	Média do erro de Reconstrução por Voronoi e por Kriging a partir de $\Psi_{3_S}$ com Processo Regular - <i>Situação1</i> e <i>Situação2</i> com $r_c = 15$ m . . . . .	92
4.47	Reconstruções por Voronoi $\Psi_{4_V}$ a partir de $\Psi_{3_S}$ - processo pontual regular e todas escalas $s$ - <i>Situação1</i> e <i>Situação2</i> com $r_c = 15$ m . . . . .	93
4.48	Reconstruções por Kriging $\Psi_{4_K}$ a partir de $\Psi_{3_S}$ - processo pontual regular e todas escalas $s$ - <i>Situação1</i> e <i>Situação2</i> com $r_c = 15$ m . . . . .	94

# Lista de Tabelas

4.1	Descritivos das Avaliações do erro para a <i>situação1</i> . . . . .	47
4.2	Descritivos das Avaliações do erro para a <i>situação2</i> . . . . .	48
4.3	Descritivos das Avaliações do erro entre a <i>situação1</i> e a <i>situação2</i> . . . . .	49
4.4	Análise quantitativa: <i>situação2</i> , Amostragem $\Psi_1$ , Voronoi e Kriging . . . . .	95
4.5	Análise quantitativa: <i>situação2</i> , Amostragem $\Psi_1$ e Agregação/Clusterização $\Psi_{3S}$ , reconstrução por Kriging . . . . .	96
4.6	Análise quantitativa: <i>situação2</i> , Agregação/Clusterização SKATER $\Psi_{3S}$ e LEACH $\Psi_{3L}$ , reconstrução por Kriging . . . . .	96

# Capítulo 1

## Introdução

Neste trabalho propomos a modelagem de uma rede de sensores sem fios, no contexto do processamento de sinais, como sendo formado pelas etapas de amostragem, clusterização, agregação e reconstrução de um fenômeno de interesse para, com isso, calcular medidas de desempenho de interesse prático.

Na composição desse modelo, construímos diversas abstrações. Cada uma das abstrações representa uma simplificação dos seguintes aspectos: (i) região monitorada, (ii) fenômeno em observação, (iii) distribuição dos sensores, (iv) sensores e suas características, (v) amostragem, (vi) clusterização, (vii) agregação e (viii) reconstrução.

Definida a modelagem, implementamos as abstrações considerando dois diferentes contextos, denominados *situação1* e *situação2*, para a região de percepção dos sensores: na primeira cada sensor monitora todos os pontos dentro da sua célula de Voronoi, enquanto na segunda essa região é definida por uma função característica de suporte constante. Ao traçarmos um paralelo entre diferentes comportamentos para nossa rede, estamos fornecendo mais subsídios para as avaliações do modelo proposto.

A partir dos modelos definidos e implementados, para cada situação, realizamos simulações da nossa rede de sensores de acordo com um estudo Monte Carlo para calcular estimadores de desempenho. Em particular, calculamos medidas do erro introduzido no processo de monitoramento do sinal.

Ao final das simulações, avaliamos o desempenho da nossa rede de sensores quanto ao erro de reconstrução do fenômeno monitorado, analisando os diferentes contextos e os fatores de impacto para as operações da rede de sensores e, conseqüentemente, para o processo de reconstrução.

As principais contribuições desta dissertação são:

- estudo o funcionamento das redes de sensores sem fios como um processo de amostragem, clusterização, agregação e reconstrução de fenômenos de interesse (seção 3.3);
- utilizando essa visão, a idealização de um modelo flexível para essa rede de sensores e suas operações;
- a proposta de uma medida de erro para avaliar o funcionamento das redes de sensores sem fios, apresentada na seção 3.5;
- a proposta de uma experiência de relevância real (a medição de luz em uma floresta) como modelo para a avaliação do desempenho das operações de amostragem dos sensores e das operações de dois protocolos de clusterização/agregação (capítulo 3);
- a discriminação de fatores de impacto potencial no desempenho dessas operações, como por exemplo, a granularidade do fenômeno observado, a distribuição espacial dos sensores, as características de percepção e comunicação dos sensores, além das características dos protocolos de clusterização/agregação;
- para quantificar esse efeito, o uso de uma experiência Monte Carlo com dois ingredientes estocásticos: campos gaussianos para descrever a iluminação (proposta feita por Reis et al., 2007, e analisada em detalhes na seção 2.4.1), e processos pontuais para modelar a distribuição espacial de sensores (proposta feita por Frery et al., 2008, ver seção 2.4.2).

Embora o debate e a produção científica sobre o tema *Rede de Sensores sem Fios* venha se intensificando nas últimas três décadas, abordando os diversos desafios inerentes a essa tecnologia e suas promessas, pesquisando na base ISI Web of Knowledge (Thompson Reuters, 2007) constatamos não haver

na literatura muitos trabalhos relacionados à rede de sensores sem fios sob o ponto de vista da estimação do erro.

Os resultados deste trabalho podem ser imediatamente aproveitados para a proposta de técnicas dinâmicas de gerenciamento de redes de sensores. Essa bem como outras linhas de pesquisa são apontadas no final deste trabalho.

No restante desta seção apresentamos alguns artigos que de uma forma ou de outra se relacionam com o nosso trabalho por abordar, no contexto da rede de sensores, um ou mais dos seguintes ingredientes: reconstrução do sinal, estimação do erro, processos pontuais, campos aleatórios, cobertura de percepção e comunicação.

Uma das primeiras motivações para a elaboração deste estudo foi a proposta apresentada pelo trabalho de Reis et al. (2007). Nele, os autores apresentam uma alternativa aos usuais protocolos de roteamento baseados em *clusters* que, considerando apenas as informações de distância geográfica, agrupam os sensores realizando agregação para otimizar o consumo de energia da rede. Desconsiderando os aspectos relacionados à energia, é proposta a técnica SKATER (*Spatial 'K'luster Analysis by Tree Edge Removal*) de clusterização orientada a dados, que considera, além da distância geográfica, a homogeneidade dos dados entre os sensores agrupados. Avaliamos o desempenho relativo entre o SKATER e o protocolo LEACH (Heinzelman et al., 2002) quanto à qualidade de reconstrução do fenômeno de iluminação com granularidade descrita por um campo aleatório gaussiano simulando a distribuição regular de cem sensores.

No trabalho de Assunção et al. (2006), os autores já apresentavam o SKATER como uma alternativa interessante aos métodos de regionalização, principalmente quando a homogeneidade das regiões é um requisito imposto pela aplicação. Nesse artigo, o algoritmo de clusterização, baseado no particionamento da árvore de mínimo custo, utilizado pelo SKATER é apresentado em maiores detalhes.

O trabalho de Frery et al. (2008) segue na linha da contribuição de Reis et al. (2007). Aquele utiliza a mesma comparação entre diferentes abordagens de clusterização, apresentando um estudo da estimação do erro em rede de sensores, considerando além dos protocolos LEACH e SKATER e da granularidade do fenômeno, alguns outros ingredientes como: (i) a utilização de processos pontuais modelando diferentes comportamentos para a distribuição sensores (regular, repulsiva, aleatório e atrativa), (ii) a utilização do diagrama de Voronoi para o processo de amostragem e reconstrução e (iii) a proposta detalhada de experiências Monte Carlo para quantificar e estimar o erro de reconstrução do fenômeno.

Nowak et al. (2004) consideram o problema de estimar campos aleatórios bi-dimensionais não-homogêneos com redes de sensores sem fios. Os autores propõem um método para estimar fronteiras, isto é, mudanças abruptas de comportamento entre regiões. Como simplificação, eles consideram os campos não-homogêneos como sendo compostos por dois campos homogêneos (campos gaussianos estacionários com média zero) separados por uma fronteira suave. Distribuindo  $n$  sensores regularmente numa região plana de lados iguais, e definindo a área de percepção dos sensores pelo particionamento dessa região (área quadrática de percepção), a rede de sensores é utilizada para amostrar, estimar e enviar os dados de estimação para um destino remoto. Além disto, é modelada a relação entre a acurácia da estimação e o consumo de energia em função do número de sensores.

Em nosso trabalho, para modelarmos o fenômeno iluminação a ser monitorado pela rede de sensores, adotamos a utilização de um campo aleatório gaussiano estacionário e isotrópico, com média zero. Na Seção 2.4 (página 8) do capítulo 2 trazemos ao leitor algumas definições importantes relacionadas a esse processo estocástico.

Palit (1997) aponta a inviabilidade, em certas aplicações, da abordagem usual de reconstrução de um fenômeno ou sinal por métodos que consideram simplesmente a média ou a média ponderada dos valores observados pelos sensores. Como alternativa, esse trabalho propõe um estimador baseado no método da máxima verossimilhança. Para comparar esses estimadores, são conduzidas simulações e realizadas análises numéricas e estatísticas. Dentre outras conclusões, o artigo afirma que fatores como nível de ruído do sinal, grau de incerteza (relativo às propriedades da variância) e densidade dos sensores podem beneficiar um ou outro estimador.

Em nossa abordagem da reconstrução do fenômeno iluminação, modelamos dois processos de reconstrução utilizando, respectivamente, células de Voronoi e estimação por Kriging. No processo de reconstrução por Voronoi, utilizamos a média como estimador da reconstrução. No processo de reconstrução por Kriging, a reconstrução de fenômeno é realizada utilizando-se um estimador pelo método da máxima verossimilhança. Na Seção 3.3.8 (página 31) apresentamos nossa modelagem para o processo de reconstrução.

No estudo apresentado por Wang et al. (2006b), os autores abordam os problemas relacionados à localização, cobertura de percepção e comunicação em redes de sensores sem fios. Eles propõem um

protocolo distribuído que utiliza as características de percepção e comunicação dos sensores para avaliar a existência de áreas sem cobertura de percepção e para ajustar, dinamicamente, as posições dos sensores da rede buscando uma melhor monitoração. O raio de comunicação dos sensores é definido em 20 m. É utilizado um modelo isotrópico de percepção definindo-se a área de percepção dos sensores como circular e de raio 6 m. O diagrama de Voronoi é computado pela rede a partir das informações de localização compartilhadas entre os sensores e a sua acurácia depende das características de comunicação dos sensores. Dentre outras conclusões, os autores apontam que o desempenho do protocolo proposto depende muito mais da razão entre raio de comunicação e raio de percepção do que propriamente das características de percepção dos sensores isoladamente.

Nesta dissertação, embora não tratemos das questões de localização e *auto-organização*, consideramos diversos aspectos abordados por Wang et al. (2006b). Na *situação1*, utilizamos o particionamento por diagrama de Voronoi para a amostragem, clusterização/agregação e, por fim, reconstrução do fenômeno monitorado. Nesta situação, embora as áreas de percepção dos sensores não sejam circulares, elas seguem o modelo isotrópico de percepção. O modelo de comunicação adotado para a *situação1*, utiliza a relação de vizinhança entre os sensores (células de Voronoi vizinhas). Já na *situação2*, o raio de comunicação  $r_c$  definido por padrão é de 36 m e o raio de percepção  $r_p \approx 5.6418$  m confere uma área circular que também segue o modelo isotrópico de percepção.

Mhatre et al. (2005) utilizam processos pontuais homogêneos bi-dimensionais para distribuir sensores heterogêneos sobre uma área. Cada um dos dois tipos de sensores utilizados apresenta um perfil distinto de intensidade de distribuição (número de sensores por unidade de área) e de energia disponível. A função de um destes tipos de sensores é apenas a de monitoramento, enquanto a do outro é de *cluster head* e *sink*. Os autores apresentam um estudo sobre a otimização do ciclo de vida da rede de sensores em função dos parâmetros intensidade e energia, considerando as preocupações com conectividade e cobertura de percepção. É feita uma comparação desses resultados com os obtidos considerando a distribuição regular dos sensores.

Em nosso estudo, a cada simulação distribuímos os sensores, homogêneos, utilizando processos pontuais homogêneos e não-homogêneos, a depender do tipo de comportamento desejado para a distribuição dos sensores. Embora reconheçamos a importância da conservação de energia para o ciclo de vida da rede de sensores, direcionamos nosso foco para os processos de amostragem, clusterização, agregação e reconstrução utilizando rede de sensores.

Batalin et al. (2004) apresentam um estudo relacionado ao processo de amostragem utilizando-se uma rede de sensores sem fios para monitorar a iluminação incidente numa região de floresta. São apresentados os diversos desafios relacionados a tarefa de monitoramento, além de vários resultados dos experimentos realizados.

Nesta dissertação, modelamos uma região de floresta como sendo o ambiente a ser monitorado pela rede de sensores. Em nossas abstrações adotamos uma série de simplificações, considerando o ambiente da floresta como favorável às operações da rede de sensores.

O resto do trabalho está estruturado da seguinte maneira:

**Capítulo 2:** Apresenta as definições e aspectos importantes sobre as redes de sensores, além da notação a ser empregada no restante do trabalho.

**Capítulo 3:** Descreve o experimento em detalhes, a nossa modelagem e a experiência Monte Carlo.

**Capítulo 4:** Exibe os resultados obtidos com a experiência Monte Carlo.

**Capítulo 5:** Conclui a dissertação discutindo os resultados e apontando trabalhos futuros.

A seguir, apresentamos no capítulo 2 algumas notações e conceitos relacionados à rede de sensores sem fios que serão importantes no decorrer deste trabalho.

# Capítulo 2

## Definições

A preparação deste trabalho demandou a consulta a livros de texto e a artigos de diversas áreas, cada uma com suas peculiaridades de estilo e de notação. Procuramos, sempre que possível, manter uma abordagem e uma notação unificadas para, com isso, trazer uma contribuição do ponto de vista da modelagem destes sistemas que são as redes de sensores sem fios.

### 2.1 Notação e definições

Nesta seção apresentamos algumas definições e a notação adotada para os diversos aspectos relacionado à rede de sensores que o leitor irá se deparar no decorrer deste estudo.

Vários conceitos de teoria dos grafos aparecerão nesta dissertação, dentre eles o de grafo, de conectividade, árvores e ciclos. Para tanto, consultamos o texto de Bollobas (1998).

#### Modelo e área de percepção

Existem diversos tipos de sensores com funções e objetivos específicos. Cada tipo de sensor apresenta um modelo particular de percepção ou de sensibilidade que é caracterizado por sua área de percepção  $A_p$ , resolução e acurácia.

A área de percepção  $A_p$  de um sensor depende de múltiplos fatores

- intensidade do sinal sendo monitorado;
- taxa de atenuação de propagação do sinal;
- nível de confiança de percepção desejado;

Especificado o nível de confiança desejado, podemos estabelecer o raio de percepção  $r_p$  de um sensor.

Neste trabalho, considerando a utilização de sensores de luminosidade, definimos a área de percepção  $A_p$  dos sensores de forma diferente para cada um dos contextos analisados, *situação1* e *situação2*. Na *situação1* as áreas de percepção  $A_p$  dos sensores da rede são definidas pelas células do diagrama de Voronoi (ou seja, são polígonos de áreas variáveis). Na *situação2*, a área circular de percepção  $A_p$ , idêntica para todos os sensores, é definida pelo raio de percepção  $r_p$ .

Para ambas as situações, consideramos que o modelo de percepção é isotrópico, ou seja, o sensor apresenta a mesma sensibilidade em todas as direções da área de percepção.

Ehrlich et al. (2001) apresentam alguns aspectos relacionados à área de percepção e à distribuição de sensibilidade de fotossensores. Os autores ainda ilustram com imagens como é a percepção do tipo “olho-de-peixe” (*fisheye*).

#### Área de comunicação - $A_c$

Da mesma forma que para a área de percepção, adotamos diferentes abordagens para as áreas de comunicação  $A_c$  dos sensores em cada situação. Na *situação1*, dois sensores são vizinhos se suas células de Voronoi compartilham de pelo menos um vértice. Na *situação2*, dois sensores são vizinhos se um está no raio de comunicação  $r_c$  do outro. As duas relações de vizinhança consideradas são simétricas, isto é, se o nó  $i$  é vizinho do nó  $j$ , então o nó  $j$  é vizinho do nó  $i$ . Essas relações de vizinhança garantem

comunicação *one-hop* entre sensores vizinhos. A comunicação entre sensores não vizinhos se dá por comunicação *multi-hop*.

Neste trabalho, consideramos a comunicação sob o ponto de vista da formação dos *clusters*, desconsiderando os aspectos relacionados as camadas física e de enlace.

### Operações da rede de sensores

Neste trabalho, os dados resultantes das operações realizadas pela rede de sensores são classificados em três conjuntos

- dados da amostragem individual ( $\Psi_1$ )
- dados de agregação dos sensores clusterizados pela técnica LEACH ( $\Psi_{3L}$ )
- dados de agregação dos sensores clusterizados pela técnica SKATER ( $\Psi_{3S}$ )

A partir de um desses conjuntos são aplicados os dois processos de reconstrução de fenômeno monitorado

- reconstrução por Voronoi ( $\Psi_{4V}$ )
- reconstrução por Kriging ( $\Psi_{4K}$ )

### Diagrama de Voronoi

O diagrama de Voronoi é uma importante estrutura de dados da Geometria Computacional.

Dentre os inúmeros livros que tratam sobre Diagramas de Voronoi, sugiremos ao leitor o trabalho de Okabe et al. (1992), a partir do qual extraímos a seguinte definição.

**Definição 1 (Diagrama de Voronoi no plano).** *Dado um conjunto finito de dois ou mais pontos distintos no plano Euclidiano, associamos todas as coordenadas deste espaço com o(s) membro(s) mais próximo(s) do conjunto de pontos, considerando a distância euclidiana. O resultado é o particionamento do espaço num conjunto de regiões. Chamamos este particionamento de **diagrama de Voronoi gerado a partir do conjunto de pontos, e as regiões de polígonos de Voronoi.***

Neste trabalho, utilizamos o termo *células de Voronoi* no lugar de *polígonos de Voronoi*.

O diagrama de Voronoi é utilizado no processo de amostragem da *situação 1*, e no processo de reconstrução por Voronoi  $\Psi_{4V}$  de ambas as situações.

## 2.2 Redes de sensores sem fio

Dentre os muitos trabalhos abordando rede de sensores sem fios, indicamos ao leitor o artigo de Akyildiz et al. (2002). Embora tenha sido publicado há alguns anos, a visão geral sobre o tema apresentada pelos autores expõe fatores ainda atuais do ponto de vista do projeto da rede, dentre eles o modelo de camadas, os problemas a serem resolvidos, as promessas e potencialidades dessa tecnologia.

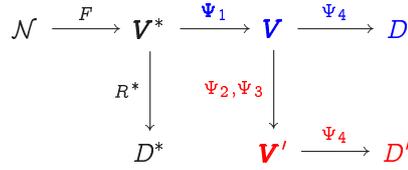
Sugerimos também o artigo de Baronti et al. (2007). Esse trabalho, mais recente, apresenta dois padrões criados para as redes de sensores sem fios: *IEEE 802.15.4* e *ZigBee*. O primeiro padrão trata dos aspectos das camadas física e de enlace. O padrão *ZigBee* padroniza as camadas de rede e de aplicação.

Fazemos aqui referência a dois trabalhos que tratam de outro tipo de rede de sensores, os artigos de Heidemann et al. (2006) e de Pompili et al. (2006). Embora tratem de redes de sensores subaquáticas, sua leitura nos mostra que os desafios e problemas enfrentados por estas tecnologias de rede de sensores se entrelaçam, independentemente do meio físico.

### 2.2.1 Representação de uma rede de sensores sem fio

Aquino et al. (2008) e Frery et al. (2008) consideram o funcionamento das redes de sensores sem fios no contexto do processamento de sinais. O segundo desses artigos apresenta essa operação como um processo de amostragem, clusterização, agregação e reconstrução do fenômeno observado. Nesta dissertação

fazemos uma reinterpretação dessa modelagem, tal como mostrado no seguinte diagrama



onde  $\mathcal{N}$  representa o ambiente na riqueza dos seus detalhes (em nossas simulações, a região de floresta),  $F$  o fenômeno de interesse (em nosso caso, a iluminação incidente na região) com seu valores no domínio espaço-temporal  $\mathbf{V}^*$ . Se fosse possível a completa e íntegra observação de  $F$ , poderíamos estabelecer um conjunto ideal de regras ou recursos  $R^*$  para a tomada de decisões ideais  $D^*$ .

Ao invés da situação ideal, podemos utilizar uma rede com  $n$  sensores  $S = \{S_1, \dots, S_n\}$  para amostrar o fenômeno, onde cada sensor observa o ambiente e reporta seu valor de amostragem  $\Psi_{1S_i}$ . Do conjunto das observações (amostragens) individuais dos sensores  $\Psi_1 = \{\Psi_{1S_1}, \dots, \Psi_{1S_n}\}$ , obtemos o domínio espaço-temporal possível  $\mathbf{V}$  a partir do qual aplicamos os processos de reconstrução  $\Psi_4$  cujos resultados irão auxiliar nas decisões possíveis  $D$ .

Reportar  $\mathbf{V}$  aos usuários da rede pode ser muito dispendioso em termos de energia e, desta forma, a vida útil da rede pode ficar comprometida. Em função disso, procuram-se diversas estratégias de otimizações como, por exemplo, a redução de dados e/ou a eliminação de redundâncias por clusterização e agregação (Nakamura et al., 2007).

Desta forma, a partir de  $\mathbf{V}$ , podem ser aplicadas técnicas de redução como as operações de clusterização  $\Psi_2$  (em nosso caso, os protocolos LEACH e SKATER) e de agregação  $\Psi_3$  realizadas pela rede, produzindo um domínio espaço-temporal mais reduzido  $\mathbf{V}'$  a partir do qual são aplicados processos de reconstrução  $\Psi_4$  produzindo auxílio para as decisões possíveis  $D'$ . O desempenho da rede de sensores irá determinar a qualidade dos subsídios necessários para as tomadas de decisão.

## 2.2.2 Energia e ciclo de vida da WSN

Muitas pesquisas vêm sendo desenvolvidas abordando vários aspectos relacionados à melhor gerência dos recursos desse novo paradigma de processamento distribuído que são as redes de sensores sem fios.

Um dos maiores desafios relacionados às redes de sensores sem fios é a utilização otimizada do recurso energia, prolongando sua vida útil, ou seja, o seu ciclo de vida.

Segundo Chen & Zhao (2005), algumas das importantes características que afetam o ciclo de vida da rede são: (i) a arquitetura de rede, se plana ou hierárquica, (ii) a forma da coleta de dados, se orientada a eventos ou sob demanda dos usuários e (iii) o modelo do canal de comunicação e consumo de energia.

Por toda a literatura, é de comum entendimento a relação direta entre a comunicação e o consumo de energia, de forma que maximizar a vida útil da rede de sensores significa minimizar a comunicação entre os nós.

Conforme aponta Sadler (2005), na elaboração de um projeto de redes de sensores sem fios devem ser considerados alguns princípios em função da atual limitação de disponibilidade de energia:

- sob o ponto de vista do processamento de sinais: otimizar as tarefas distribuídas de detecção e estimação da rede e serviços minimizando os custos com comunicação;
- sob o ponto de vista da comunicação: garantir os objetivos da rede e, ao mesmo tempo, minimizar os custos com *escuta ociosa* (*idle listening*) dos sensores e com as tarefas de configuração e gerenciamento da rede;
- sob o ponto de vista de sistemas: explorar a utilização de *hardware* de baixo consumo.

Alguns questionamentos que poderíamos levantar nesse projeto seriam: a comunicação é *one-hop* ou *multi-hop*? A arquitetura é fixa ou não? Os sensores são homogêneos ou heterogêneos? Qual a densidade dos sensores na área? Os sensores serão distribuídos aleatória ou regularmente? Qual a estratégia de sincronização e localização? Quais as condições de propagação de rádio?

Como nossa intenção nesta seção foi apenas a de levantar algumas questões e aspectos relacionados às redes de sensores e seu ciclo de vida, organizamos, a seguir, uma relação de referências pertinentes a esse assunto.

Entre os trabalhos relacionados à gerência do recurso energia da rede de sensores, sugerimos a leitura de Mini et al. (2002). Nesse trabalho, os autores utilizam uma abordagem probabilística e propõem um modelo para estimar o consumo de energia da rede de sensores.

Dentre os vários trabalhos relacionados aos problemas e soluções da camada de acesso ao meio (*MAC*) da pilha de protocolos, sugerimos Ye et al. (2004), McHenry & Heidemann (2007), Ye & Heidemann (2006) e Demirkol et al. (2006).

Outro importante tema, foco de intensa pesquisa pela comunidade, fortemente relacionado ao consumo de energia é o roteamento. Alguns dentre os muitos trabalhos são os de Chang & Tassiulas (2004), de Al-Karaki & Kamal (2004) e de Luo et al. (2007).

Ainda na camada de rede, e inerentemente ligadas ao roteamento, estão as técnicas de agrupamento ou clusterização. Dentre os vários trabalhos na literatura, sugerimos Heinzelman et al. (2000) que trata do protocolo LEACH (uma das soluções de clusterização utilizada nesta dissertação) e Younis & Fahmy (2004) que traz uma comparação de desempenho entre o protocolo proposto e o protocolo LEACH.

Na camada de transporte, sugerimos a leitura do trabalho de Wang et al. (2006a).

A capacidade de sincronização entre os sensores da rede é um importante aspecto, principalmente quanto ao processamento de sinais e comunicação. Sugerimos como leitura sobre esse tema o trabalho de Faizulkhakov (2007).

Considerando o processamento de sinais mais especificamente quanto às necessidades das aplicações no contexto das redes de sensores sem fios, sugerimos a leitura do trabalho de Zhao et al. (2006).

Um outro requisito importante para as redes de sensores é a tolerância a falhas. Neste sentido, sugerimos uma leitura de Paradis & Han (2007) e de Chessa & Santi (2002).

Uma característica da rede de sensores, muitas vezes desejada, que pode prolongar a vida útil da rede é a auto-organização. Entre alguns dos seus objetivos estão a redundância para reduzir falhas e o balanceamento de carga para otimizar o consumo. Dos vários trabalhos abordando esse tema, sugerimos o de Cerpa & Estrin (2004).

Finalizando esta relação, sugerimos a consulta ao trabalho de Jiang et al. (2005) que, como muitos outros estudos, propõe um projeto de sensor com características que favorecem a uma maior vida útil da rede.

## 2.3 Consulta, processamento e aquisição de informação em WSN

Consideremos a nossa representação da rede de sensores sem fios como um sistema de aquisição de informação, conforme o diagrama da página 6. Resguardados dos detalhes, suponhamos um projeto de redes com as seguintes características

- a região monitorada é uma floresta de 100 m × 100 m
- foram distribuídos 100 sensores de temperatura de forma regular na região monitorada;
- na rede coexistem comunicação *one-hop* e *multi-hop* com a estação base;
- a rede é gerenciada de forma centralizada por um software que se encarrega de fazer as consultas do usuário
- o software de gerenciamento é capaz de identificar e de alertar a ocorrência dos eventos de interesse: temperatura superior a 40 °C.

Consideremos também que, por construção, na ocorrência do evento de interesse sejam obrigatórias certas tomadas de decisão pelos usuários da rede.

A construção deste cenário tem por objetivo nos auxiliar na apresentação de alguns aspectos que devem ser levados em conta na utilização de rede de sensores como um sistema de aquisição de informação.

Alguns questionamentos que poderíamos levantar deste projeto são os seguintes:

- qual o tipo de roteamento utilizado pelos sensores?
- é utilizada alguma técnica de clusterização entre os sensores?
- é levada em consideração a correlação dos dados entre os sensores?
- é adotada alguma estratégia de sincronização entre os sensores?

- ocorre algum tipo de agregação entre os dados dos sensores?
- é utilizada alguma técnica de compressão de dados pelos sensores?

O sucesso da utilização de rede de sensores considerando os contextos da consulta, processamento e aquisição de informação dependerá de como o projeto de rede responde a esses e outros questionamentos.

Diversos estudos vêm sendo elaborados pela comunidade científica com o intuito de unir os diferentes, mas inerentemente ligados, aspectos relacionados a roteamento, agregação e gerenciamento de dados. Uma promessa, na recente literatura, é a utilização das técnicas de agregação *In-Network*.

Uma interessante pesquisa sobre as técnicas *In-Network* é apresentada no trabalho de Fasolo et al. (2007). Desse trabalho extraímos a seguinte definição

**Definição 2 (Agregação *In-Network*).** *Agregação In-Network é o processo global de aquisição e roteamento de informação através de uma rede multi-hop, processando os dados nos nós intermediários com o objetivo de redução do consumo de recursos (em particular de energia) para, desse modo, aumentar o ciclo de vida da rede.*

Como na Seção 2.2.2, nesta seção disponibilizamos ao leitor uma relação de trabalhos que abordam temas como roteamento, clusterização, disseminação, agregação e fusão de dados no contexto da rede de sensores sem fios.

Yoon & Shahabi (2007) propõem o protocolo *CAG* de clusterização e agregação *In-Network*. Considerando a correlação espaço-temporal dos dados e a eficiência de consumo de energia, o *CAG* provê respostas às consultas com níveis aceitáveis de erro em função dos requisitos dos usuários. Nesta dissertação, defendemos a flexibilidade da nossa modelagem traçando um paralelo entre o nosso modelo e os vários aspectos relacionados com o *CAG* (ver Seção 3.4, página 37).

Reis et al. (2007) e Assunção et al. (2006) apresentam o protocolo *SKATER* de clusterização orientada a dados. Esse protocolo é utilizado nesta dissertação como um dos dois protocolos do nosso modelo de clusterização (ver Seção 3.3.6, página 26).

Heinzelman et al. (2002) apresentam o protocolo *LEACH* de clusterização e comunicação. Utilizamos esse protocolo como a outra opção do nosso modelo de clusterização. Algumas considerações de implementação relevantes sobre a nossa abordagem referente ao *LEACH* são apresentadas na Seção 3.6.3.8 (página 43).

Dentre os vários trabalhos na literatura sobre agregação de dados, sugerimos ao leitor os de Kalpakis et al. (2003), de Tan & Korpeoglu (2003) e de Akkaya et al. (2008).

Quanto à fusão de dados em rede de sensores sem fios, sugerimos os trabalhos de Nakamura et al. (2007) e de Nakamura et al. (2005). No primeiro trabalho é feito um amplo levantamento dos métodos, modelos e classificação de técnicas de fusão de dados em rede de sensores. No segundo, os autores tratam do problema da reconstrução da topologia de disseminação dos dados combinando técnicas de disseminação e fusão de dados.

Um estudo relacionando algoritmos de disseminação com consumo de energia é apresentado por Machado et al. (2005).

Por fim, tratando do tema recuperação de dados, sugerimos os trabalhos de Dong et al. (2006) e de Zhao & Tong (2007).

## 2.4 Processos Estocásticos

Nesta seção discutimos brevemente sobre processos estocásticos, focando mais especificamente nos tipos de processos utilizados em nossas simulações: (i) campos aleatórios e (ii) processos pontuais. Definições de alguns dos processos estocásticos clássicos podem ser vistas em Karlin & Taylor (1975).

Antes de continuarmos com os processos estocásticos, apresentamos abaixo algumas definições da Teoria das Probabilidades. Dentre os inúmeros livros desta área, sugiremos ao leitor os trabalhos de Grinstead & Snell (1997) e de Dekking et al. (2005).

**Definição 3 (Espaço Amostral).** *O espaço amostral  $\Omega$  de uma variável aleatória  $X$  é o conjunto de todos os possíveis resultados de  $X$ .*

**Definição 4 (Função de distribuição acumulada).** *A função de distribuição acumulada de uma variável aleatória  $X$  é uma das formas mais convenientes de se conhecer ou caracterizar a sua distribuição. Definida como  $F(t) = \Pr(X \leq t)$ , a função de distribuição acumulada apresenta as seguintes propriedades:*

1.  $F$  é não decrescente, isto é, se  $t_1 < t_2$  então  $F(t_1) \leq F(t_2)$
2.  $F$  é contínua à direita, isto é, se  $t_n \downarrow t$  quando  $n \rightarrow \infty$  então  $F(t_n) \rightarrow F(t)$
3.  $F(t_n) \rightarrow 0$  se  $t_n \rightarrow -\infty$  e  $F(t_n) \rightarrow 1$  se  $t_n \rightarrow \infty$ , quando  $n \rightarrow \infty$ .

**Definição 5 (Variáveis aleatórias discretas).** Uma variável aleatória discreta possui um espaço amostral  $\Omega$  finito ou infinito enumerável. A sua distribuição é completamente caracterizada pelo vetor de probabilidades  $\Pr(X = x_i)_{x_i \in \Omega}$ , que atribui uma probabilidade  $p_i$  a cada resultado  $x_i$  da variável aleatória  $X$ .

**Definição 6 (Variáveis aleatórias contínuas).** Se existir uma função  $f$  tal que  $f(t) = dF(t)/dt$ , com  $F$  a função de distribuição acumulada da variável aleatória  $X$ , então dizemos que  $X$  é uma variável aleatória contínua e que  $f$  é a sua função de densidade.

A função de densidade de uma variável aleatória contínua caracteriza a sua distribuição. Esta função apresenta duas propriedades: ela é não negativa  $f \geq 0$ , e o valor da sua integral é 1 ou seja  $\int f = 1$ .

**Definição 7 (Esperança).** A esperança  $E(X)$  de uma variável aleatória contínua  $X$ , existindo a integral, é dada por

$$E(X) = \int_{\mathbb{R}} xf(x) dx,$$

onde  $f$  é a função densidade que caracteriza a distribuição de  $X$ .

**Definição 8 (Esperança de uma função).** Sejam  $X$  uma variável aleatória real contínua e  $g: \mathbb{R} \rightarrow \mathbb{R}$  uma função “bem comportada”. Se a integral existir, dizemos que

$$E(g(X)) = \int_{\mathbb{R}} g(x)f(x) dx$$

é a esperança de  $g(X)$ .

**Definição 9 (Variância).** Se  $E(X)$  é a esperança de uma variável aleatória  $X$ , então a variância dessa variável aleatória é definida como

$$\text{Var}(X) = E(X - E(X))^2 = E(X^2) - (E(X))^2,$$

desde que  $E(X^2)$  exista.

**Definição 10 (Covariância).** A covariância entre duas variáveis aleatórias reais  $X$  e  $Y$ , definidas no mesmo espaço de probabilidade, é definida como

$$\text{Cov}(X, Y) = E(XY) - E(X)E(Y)$$

**Definição 11 (Correlação).** A correlação entre duas variáveis aleatórias reais  $X$  e  $Y$ , definidas no mesmo espaço de probabilidade, é definida como

$$\rho(X, Y) = \frac{\text{Cov}(X, Y)}{\sqrt{\text{Var}(X)\text{Var}(Y)}}.$$

A distribuição gaussiana multivariada será de particular interesse no nosso trabalho. Para o que segue consultamos o livro de Velho et al. (2008).

**Definição 12 (Densidade gaussiana multivariada).** O vetor de variáveis aleatórias  $\mathbf{X}$  segue uma lei gaussiana  $m$ -variada de média  $\boldsymbol{\mu} = (\mu_1, \dots, \mu_m)' \in \mathbb{R}^m$  e matriz de covariância  $\Sigma$  positiva definida se a sua densidade é dada por

$$p(\mathbf{x}) = \frac{1}{(2\pi)^{m/2} |\Sigma|^{1/2}} \exp\left\{-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})' \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})\right\}, \quad (2.1)$$

onde  $\mathbf{x} = (x_1, \dots, x_m)'$  é um ponto de  $\mathbb{R}^m$ .

A média  $\mu$  é o ponto modal da distribuição, isto é, onde o máximo de  $p$  está localizado. Pelo fato da matriz de covariância ser positiva definida, a sua inversa  $\Sigma^{-1}$  existe. A matriz de covariância é da forma  $\Sigma = (\sigma_{ij})$  onde

$$\begin{aligned}\sigma_{ij} &= \sigma_{ji} \text{ é a covariância entre as componentes } i \text{ e } j, \\ \sigma_{ii} &= \sigma_i^2 > 0 \text{ é a variância da componente } i.\end{aligned}$$

A covariância entre as componentes  $i$  e  $j$  pode ser escrita em termos da sua correlação  $-1 < \rho_{ij} < 1$ , da seguinte forma:

$$\sigma_{ij} = \rho_{ij}\sigma_i\sigma_j.$$

Um fato importante desta distribuição é que o vetor de médias e a matriz de covariância a caracterizam por completo. Mais detalhes a respeito desta distribuição podem ser vistos nos textos de Krzanowski (1988), de Muirhead (1982) e de Tong (1990).

Na Teoria das Probabilidades, os processos estocásticos, também referidos como processos aleatórios, representam a contrapartida para os processos determinísticos cuja evolução com o tempo é conhecida e esperada. A evolução de um processo estocástico é descrita por meio de distribuições de probabilidades.

**Definição 13** (Processo Estocástico). *Um processo estocástico é uma coleção de variáveis aleatórias  $\{X_i\}_{i \in I}$ .*

O índice processo  $I$  pode ser discreto ou contínuo em uma ou mais dimensões, e as variáveis aleatórias que o compõem podem ser contínuas ou discretas, uni ou multivariadas.

Um processo estocástico fica completamente especificado pela sua distribuição conjunta, mas em geral essa informação ou não está disponível explicitamente ou ela é excessivamente complexa para ser utilizada de forma direta.

Um processo estocástico pode ser pensado como uma função aleatória. O domínio no qual essa função aleatória está definida pode ser um intervalo de tempo (definido com uma sequência de variáveis aleatórias, correspondentes aos vários tempos ou instantes, conhecidas como *séries temporais*) ou uma região dos espaço (mapeada por um conjunto de variáveis aleatórias, correspondentes aos vários pontos, denominado *campo aleatório*).

A seguir, direcionamos nosso foco para os dois processos estocásticos de interesse neste trabalho.

### 2.4.1 Campos aleatórios

Um campo aleatório  $Z$  é uma coleção de variáveis aleatórias indexadas por pontos num espaço de  $d$ -dimensões, ou seja,  $Z = (Z(x) : x \in \mathbb{R}^d)$ . Num campo aleatório típico as variáveis aleatórias estão espacialmente correlacionadas segundo algum modelo, definido por uma função de covariância.

Os campos aleatórios são processos estocásticos utilizados para descrever fenômenos naturais como temperatura, umidade, luminosidade, dentre outros.

Existem diversos tipos ou modelos de campos aleatórios. Cada tipo é caracterizado por sua distribuição conjunta, da qual decorrem certas propriedades que podem ser de interesse particular para determinadas aplicações. Seguindo o texto de Schlather (1999), detalharemos a seguir algumas dessas propriedades que serão úteis para o nosso trabalho.

**Definição 14** (Campo aleatório estacionário). *Um campo aleatório  $Z$  é estacionário se  $\mathbb{E}(Z(x))$  é constante para todo  $x \in \mathbb{R}^d$  e se a função de covariância é invariante quanto à operação de translação, isto é, se*

$$\text{Cov}(x, y) = \text{Cov}(x + t, y + t), \text{ para todo } x, y, t \in \mathbb{R}^d$$

**Definição 15** (Campo aleatório isotrópico). *Um campo aleatório  $Z$  é chamado isotrópico se tanto a esperança quanto a função de covariância são invariantes quanto à operação de rotação, ou seja*

$$\begin{aligned}\mathbb{E}(Z(Ax)) &= \mathbb{E}(Z(x)) \text{ para qualquer } x \in \mathbb{R}^d \text{ e qualquer matriz de rotação } A, \\ \text{Cov}(Ax, Ay) &= \text{Cov}(x, y) \text{ para qualquer } x, y \in \mathbb{R}^d \text{ e qualquer matriz de rotação } A.\end{aligned}$$

Para descrever o fenômeno iluminação, usamos neste trabalho um campo aleatório gaussiano estacionário e isotrópico com função de covariância  $\exp(-\|x - y\|^s)$ , onde  $s > 0$  representa o parâmetro escala que caracteriza este modelo, e está relacionado com a granularidade do processo.

### 2.4.2 Processos pontuais

Processos pontuais são modelos estocásticos que descrevem a localização de pontos no espaço. Largamente estudados no âmbito da Teoria das Probabilidades, os processos pontuais são uma poderosa ferramenta estatística para modelar e analisar dados distribuídos espacialmente, despertando interesse em diversas áreas como ecologia vegetal, florestas e silvicultura, ciência dos materiais, geografia, sismologia, astronomia, epidemiologia, entre outras. Dentre as inúmeras referências sobre processos pontuais, sugerimos o trabalho de Baddeley (2006).

Um excelente recurso para explorar e aplicar processo pontuais é o pacote *spatstat* (Baddeley & Turner, 2005) disponível para a plataforma R.

Antes de discutirmos os tipos de processos pontuais, descreveremos brevemente um processo de grande importância, denominado processo de Poisson, que serve de base para construir outros processos estocásticos.

O processo Poisson é um processo estocástico usado para modelar a ocorrência de eventos aleatórios no tempo. Este processo pode ser usado para descrever uma grande variedade de fenômenos como, por exemplo, o instante de chegada dos clientes em um banco, o tempo em que substâncias radioativas emitem partículas, e a falha em dispositivos eletrônicos. É atribuída a este processo a característica da completa aleatoriedade.

Consideremos que estamos observando a chegada de clientes em um banco, a partir de tempo  $t = 0$ . Denotando  $E_{t,\Delta t}^k$  como “ $k$  eventos ocorrem no intervalo  $(t, t + \Delta t]$ ”, o processo de Poisson pode ser construído a partir das seguintes hipóteses:

$$H1) \Pr(E_{t,t+\Delta t}^k) = \Pr(E_{0,\Delta t}^k) \text{ para todo } k, t \text{ e } \Delta t.$$

$$H2) \Pr(E_{t_1,\Delta t_1}^{k_1} \cap E_{t_2,\Delta t_2}^{k_2}) = \Pr(E_{t_1,\Delta t_1}^{k_1})\Pr(E_{t_2,\Delta t_2}^{k_2}) \text{ se } (t_1,\Delta t_1] \cap (t_2,\Delta t_2] = \emptyset.$$

$$H3) \lim_{t \rightarrow 0} (\Pr(E_{0,t}^2 \text{ ou mais}) / \Pr(E_{0,t}^{\text{pelo menos } 1})) = 0.$$

Com essas hipóteses, e denotando  $\lambda = -\log \Pr(E_{0,1}^0)$ , temos que  $\Pr(E_{0,1}^0) = \exp\{-\lambda\}$  para  $t = 1$ , e  $\Pr(E_{0,t}^0) = \exp\{-\lambda t\}$  para todo  $t > 0$ .

Generalizando estes resultados podemos definir a distribuição Poisson como

$$\Pr(E_{0,t}^k) = \frac{(\lambda t)^k}{k!} \exp\{-\lambda t\}. \quad (2.2)$$

O processo Poisson é caracterizado pelo parâmetro  $\lambda$ , e sua *intensidade*  $\eta$ , definida pela função  $\eta(t) = \lambda t$ , representa o número esperado de eventos por unidade de tempo.

Considerando  $T_1, T_2, T_3, \dots$  o tempo da primeira chegada, o tempo da segunda chegada depois da primeira chegada, o tempo da terceira chegada depois da segunda chegada, e assim sucessivamente, é possível verificar que

$$\Pr(T_n \leq t) = 1 - \exp\{-\lambda t\} \quad (2.3)$$

para todo  $n \geq 1$  e  $t > 0$ .

Desta maneira, o processo Poisson pode ser definido em termos do número de eventos ou em termos do intervalo de tempo entre os eventos.

Uma propriedade muito conveniente que resulta da definição do processo Poisson concerne com a localização dos  $n$  eventos. Dado um número  $n$  de pontos num intervalo  $[a, b]$ , suas localizações são identicamente e independentemente distribuídas seguindo uma distribuição uniforme no intervalo  $[a, b]$ . Esta propriedade é bastante útil na construção de processos pontuais Poisson no  $\mathbb{R}^2$ .

Numa região  $E = [a, b] \times [a, b]$  do  $\mathbb{R}^2$ , um processo será Poisson com *intensidade*  $\eta > 0$  se o número  $n$  de pontos dos conjuntos disjuntos  $A_1, A_2, \dots \subset E$  são variáveis aleatórias independentes, e se o número de pontos  $n$  em qualquer destes conjuntos  $A_i$  segue uma distribuição Poisson com média definida por

$$\mu(A_i) = \int_{A_i} \eta(u) du, \quad (2.4)$$

onde podemos interpretar  $\eta(u) du$  como a probabilidade de precisamente um ponto ser observado numa área infinitesimalmente pequena localizada em  $u$  e com área  $du$ .

A seguir descreveremos os principais tipos dos processos pontuais, focando mais especificamente naqueles que utilizaremos em nossas simulações.

### Processos pontuais homogêneos com independência

Nestes processos, o número de eventos esperados, definido pela sua *intensidade*  $\eta$ , é considerado constante por todo o processo, isto é,  $\eta(x) = \lambda > 0$  para todo  $x \in \mathbb{R}^d$ .

Nas definições a seguir, considere os processos pontuais como sendo definidos na região  $E = [a, b] \times [a, b]$  de  $\mathbb{R}^2$ .

**Definição 16 (Processo pontual Binomial).** *Um número fixo de pontos  $n \geq 1$  é dito obedecer um processo pontual Binomial se as coordenadas destes pontos em  $E$  são resultados de variáveis aleatórias independentes e identicamente distribuídas seguindo uma distribuição uniforme em  $[a, b]$ .*

Considerando que o número  $n$  de pontos seja definido como o resultado de uma variável aleatória discreta  $N$  com média  $\mu(E)$  definida conforme a equação (2.4), podemos definir o processo pontual Poisson da seguinte forma:

**Definição 17 (Processo pontual Poisson).** *Primeiramente, observa-se  $n$ , o resultado da variável aleatória discreta  $N$  que segue a distribuição Poisson apresentada na equação (2.3) com intensidade  $\eta = \lambda t$  (podemos supor  $t = 1$  por simplicidade). Em seguida, posiciona-se os  $n$  pontos em  $E$  seguindo o processo pontual Binomial definido anteriormente. Então obtém-se como resultado uma ocorrência do processo pontual Poisson homogêneo com intensidade  $\eta = \lambda$ .*

Um definição para os processos pontuais Poisson mais formal que a definição 17 poderia ser a seguinte.

**Definição 18 (Processo pontual Poisson).** *Um processo pontual Poisson com intensidade  $\eta > 0$ , para  $t > 0$  e  $\lambda > 0$ , é uma coleção  $P_1, P_2, \dots$  de pontos localizados num conjunto compacto  $E \subset \mathbb{R}^p$ ,  $p \geq 1$ , tal que o número de pontos em qualquer conjunto  $A \subset E$ , denotado como  $N(A)$ , tem as seguintes propriedades:*

1.  $N(A)$  segue uma distribuição Poisson com média  $\mu(A)$ , definida na equação (2.4) tal que  $\eta(u)$  é constante para todos os  $u \in A$ , e
2. as variáveis aleatórias  $N(A_1), N(A_2), \dots$  são coletivamente independentes se os conjuntos  $A_1, A_2, \dots$  são disjuntos, isto é,  $\cap_{i \geq 1} A_i = \emptyset$ .

Esta versão mais formal do processo pontual de Poisson será útil para a definição do processo pontual de Poisson não homogêneo (definição 19).

Um processo pontual Binomial é um processo pontual Poisson condicionado ao número de pontos  $n$ .

Na figura 2.1 apresentamos três resultados de um processo pontual Poisson com intensidade  $\eta = 50$ . Para construir estes eventos, primeiramente observou-se três resultados,  $n_1 = 37$ ,  $n_2 = 66$  e  $n_3 = 47$ , da variável aleatória discreta  $N: \Omega \rightarrow \mathbb{N}$  que segue uma distribuição Poisson com média (intensidade) 50. Em seguida, para  $n_1$ ,  $n_2$  e  $n_3$ , foi obtido o processo pontual Binomial ilustrado nas figuras 2.1(a), 2.1(b) e 2.1(c), respectivamente.

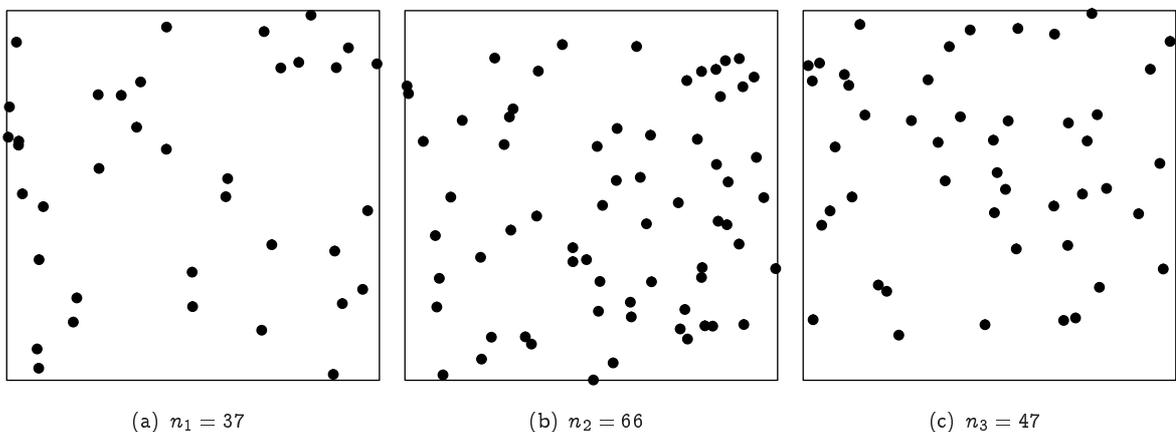


Figura 2.1: Três processos pontuais Poisson com  $\eta = 50$

Um das propriedades básicas apresentadas pela definição 18, é que a probabilidade de se observar  $n$  pontos nos conjunto  $A_1, A_2 \subset E$  é a mesma caso suas áreas sejam iguais, não importando as suas relativas localizações em  $E$ .

### Processos pontuais não-homogêneos e/ou dependentes

Nos processos pontuais não-homogêneos, a intensidade  $\eta$  pode variar conforme a área em que o processo está sendo construído. Com base nesta generalização, os processos pontuais homogêneos são um caso especial dos processos pontuais não-homogêneos onde a intensidade é constante e definida por  $\eta = \lambda$ .

Por meio dos processos pontuais não-homogêneos podemos considerar casos onde a probabilidade de se observar  $n$  pontos varie de acordo com as regiões de  $E$ , podendo certas áreas serem mais ou menos densas.

Podemos construir um processo pontual não-homogêneos definindo sua *intensidade* como uma função  $\eta: E \rightarrow \mathbb{R}_+$ , tal que  $\int_A \eta < \infty$  para qualquer conjunto  $A \subset E$ .

Seguindo essa nova abordagem, apresentamos a definição de dois processo pontuais não-homogêneos de interesse para este trabalho: o processo pontual Poisson não homogêneo e o processo pontual *Simple Sequential Inhibition*. O primeiro será utilizado para descrever uma distribuição de sensores com agrupamento, enquanto o segundo é empregado para descrever sensores espacialmente esparsos (ver seção 3.3.3, página 18).

**Definição 19 (Processo pontual Poisson não-homogêneo).** *Um processo pontual Poisson não-homogêneo ou de intensidade não constante é uma coleção  $P_1, P_2, \dots$  de pontos localizados num conjunto compacto  $E \subset \mathbb{R}^p$ ,  $p \geq 1$ , tal que o número de pontos em qualquer conjunto  $A \subset E$ , denotado como  $N(A)$ , tem as seguintes propriedades:*

1.  $N(A)$  segue uma distribuição Poisson com média  $\mu(A)$ , definida na equação 2.4 tal que o valor  $\eta(u)$  para cada  $u \in A$  varia de acordo com a função intensidade  $\eta: E \rightarrow \mathbb{R}_+$ , e
2. as variáveis aleatórias  $N(A_1), N(A_2), \dots$  são coletivamente independentes se os conjuntos  $A_1, A_2, \dots$  são disjuntos, isto é,  $\cap_{i \geq 1} A_i = \emptyset$ .

Considere, por exemplo, a função de intensidade  $\eta(x, y) = 1000e^{-\alpha x}$ . A figura 2.2 mostra ocorrências de três desses processos para diferentes valores do parâmetro  $\alpha$ . Com essa função de intensidade e para valores positivos do parâmetro, haverá uma tendência à concentração de pontos perto de valores de  $x$  próximos de zero.

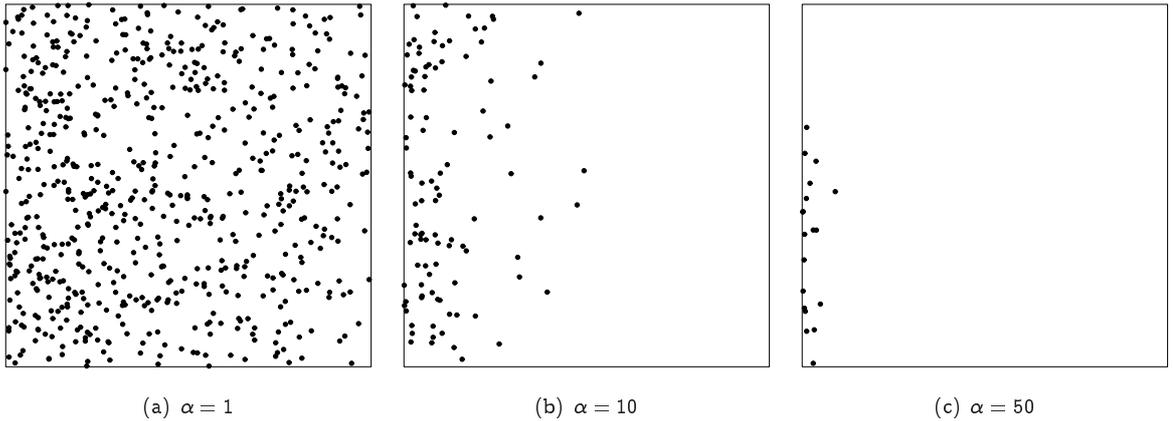


Figura 2.2: Processos de Poisson não homogêneos

**Definição 20 (Matérn's Simple Sequential Inhibition – SSI).** *Este processo é definido com um procedimento iterativo que, seguindo uma distribuição uniforme com parâmetro  $n$ , tenta colocar sequencialmente  $n$  pontos sobre a região  $E$ , observando a regra de exclusão estabelecida com base no parâmetro de exclusão  $r$ . A partir do primeiro ponto, enquanto (i) os  $n - 1$  pontos restantes não estiverem posicionados ou (ii) o número de tentativas não atingir o limite de iterações  $T$  estabelecido, posicionar um novo ponto seguindo a distribuição uniforme; se a distância do novo ponto para qualquer ponto já posicionado for menor que  $r$  então este novo ponto será rejeitado e o processo continua gerando um próximo ponto candidato.*

A figura 2.3 mostra três ocorrências de processos SSI com  $n = 50$  e valores crescentes para o parâmetro de exclusão  $r$ .

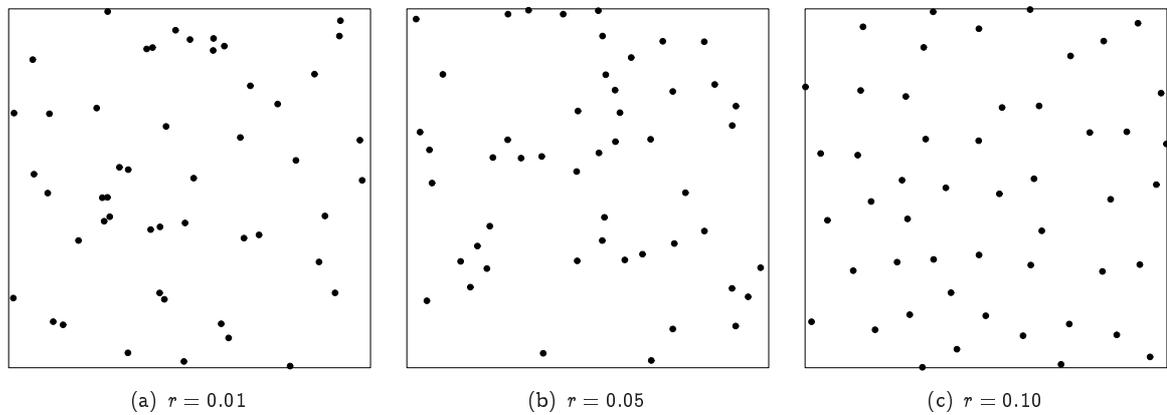


Figura 2.3: SSI com  $n = 50$

Neste capítulo apresentamos as ferramentas que serão empregadas no resto do trabalho. Em particular, definimos aqueles aspectos das redes de sensores sem fios que serão analisados nesta dissertação, bem como elementos estocásticos (os campos gaussianos e os processos pontuais) que serão empregados na metodologia proposta. No próximo capítulo apresentamos detalhadamente a metodologia de estudo proposta neste trabalho.

## Capítulo 3

# Metodologia

### 3.1 Motivação

Nos últimos cinquenta anos, cientistas e pesquisadores vêm empreendendo estudos na tentativa de definir técnicas eficientes de acesso e exploração dos biomas florestais, ricos em biodiversidade e largamente inexplorados.

Assim como a Astronáutica se preocupa com o estudo do sistema solar e das galáxias, a Hidronáutica com o estudo das profundezas dos oceanos através de seus submersíveis, a Dendronáutica, do grego *dendron* (árvore) e *náutica* (navegação), se preocupa em proporcionar aos homens e seus instrumentos a exploração dos biomas florestais. Os especialistas identificam esses biomas como detentores de milhões de espécies de vida ainda desconhecidas (Dendronautics, 2007). Como exemplo destes biomas, temos as florestas tropicais de nosso continente.

Embora diversas técnicas de exploração do dossel das florestas tenham sido desenvolvidas, cada uma delas apresenta importantes limitações. Técnicas de escaladas das árvores utilizando cordas requerem dos pesquisadores grandes esforços e habilidades. Estruturas fixas como plataformas e passarelas, embora exijam menores esforços, se limitam pela falta de mobilidade, ficando restritas a localizações predeterminadas. Os guindastes, que conferem maior mobilidade, embora relativamente caros, talvez sejam a melhor técnica utilizada para pesquisar uma região circular de floresta, abrangendo um raio máximo de cobertura de cinquenta metros. Balões dirigíveis não se limitam quanto a mobilidade e extensão, no entanto são sensíveis às condições climáticas como, por exemplo, os ventos e, como consequência disto, a principal desvantagem desta técnica é a limitação da duração dos vôos diários, atualmente não ultrapassando duas horas. Outro importante desafio na utilização dos dirigíveis é a condição de vôo estável e a necessidade de ser o mais silencioso possível durante o processo de coleta.

Consideremos a situação de precisar estimar a iluminação que chega em certa altura de uma floresta. Diversos trabalhos abordam a necessidade de se fazer esse tipo de estimativa para, com ela, inferir aspectos de interesse da dinâmica de florestas (Jennings et al., 1999; Engelbrecht & Herz, 2001).

Face às limitações das técnicas atuais de exploração do dossel das floresta apontadas acima, e motivados pelo potencial tecnológico, pela economia de recursos e pela viabilidade de execução, decidimos realizar estudos que mostrem a viabilidade de fazer essa medição com redes de sensores sem fios.

Cada sensor é capaz de medir a intensidade luminosa instantânea, de fazer algum processamento simples e de se comunicar com outros sensores. Alguns desses sensores são eleitos para realizar uma redução de informações, e para enviá-las à estação base.

Os principais fatores que devem ser analisados no projeto de uma rede de sensores sem fios para o propósito acima descrito são:

1. o número de sensores a ser distribuído na área de interesse,
2. a distribuição espacial dos sensores, que pode ser regular, repulsiva, atrativa ou indiferente (definida na Seção 2.4.2),
3. a granularidade ou escala da iluminação (ver a Seção 2.4.1),
4. o protocolo a ser utilizado para clusterização dos dados (ver Seção 3.3.6)

A agregação dos dados é considerada fixa, e dada pela média dos valores observados em cada *cluster*. São avaliadas dois tipos de funções características para os sensores: a média sobre a área definida pela

célula de Voronoi associada a cada sensor ou a média sobre a área circular de raio fixo definida pela função de resposta radial de cada sensor (ver Seção 3.3.5). O tamanho da região sob análise (ver Seção 3.3.1) é considerado fixo. A medida de comparação é o erro de reconstrução do fenômeno de interesse.

## 3.2 Proposta

A Figura 3.1 ilustra os três níveis conceituais a serem empregados neste trabalho.



Figura 3.1: Níveis conceituais do trabalho

Com a finalidade de propor abordagens de observação do fenômeno que levem a bons resultados, propomos a construção de modelos. Assim sendo, o primeiro passo da metodologia consiste em propor abstrações, isto é, hipóteses que, por serem simplificações, redundam em modelos tratáveis, para descrever cada elemento importante do fenômeno de interesse.

Os elementos identificados como importantes para descrever o fenômeno de interesse são os seguintes:

1. a área sob monitoração, isto é, a porção de floresta,
2. o fenômeno que está sendo observado, isto é, a iluminação incidente no solo,
3. a distribuição espacial dos sensores,
4. os sensores e suas características de monitoramento,
5. a amostragem,
6. dois diferentes protocolos de clusterização entre os sensores,
7. a agregação de dados,
8. o processo de reconstrução.

Cada um destes elementos é detalhado na Seção 3.3, e todos eles compõem o que denominaremos genericamente “Modelo” (ver Figura 3.2).



Figura 3.2: Modelo

Dada a complexidade do Modelo, as ferramentas analíticas e os tempos disponíveis, a extração de informações não é abordada do ponto de vista analítico. Graças à natureza essencialmente estocástica do

Modelo formulado, é possível extrair informações dele utilizando experiências Monte Carlo. Os detalhes da construção das experiências Monte Carlo são fornecidos na Seção 3.5.

Uma vez descritas as componentes fundamentais do modelo, segue a escolha das plataformas computacionais a serem empregadas, bem como as nossas considerações de implementação do modelo genérico. Neste trabalho são utilizados a plataforma R (R Development Core Team, 2006), a linguagem de programação C e um ambiente de processamento distribuído formado por um *cluster* de computadores. Os detalhes das decisões de implementação e das plataformas adotadas, denotados genericamente “**Implementação**” na Figura 3.1, são fornecidos na Seção 3.6.

O software assim desenvolvido é, finalmente, executado. Dessa execução surgem os resultados que, analisados, fornecem bases para tirar as conclusões desejadas. Essa é a “**Execução**” da Figura 3.1, que é detalhada na Seção 3.6.2.

## 3.3 Modelos

Na figura 3.2 ilustramos o nosso modelo genérico como sendo composto por oito abstrações.

Cada uma destas abstrações modela um dos elementos propostos e juntas compõem o nosso modelo de simulação.

Uma vez que são independentes uma das outras, cada uma das abstrações pode, caso seja desejável, ser remodelada de forma a cobrir diferentes aspectos por nós não abordados. Esta flexibilidade do modelo é exemplificada na Seção 3.4.

A seguir apresentamos cada uma dessas simplificações.

### 3.3.1 Região monitorada

Consideramos nos experimentos que os sensores estão espacialmente distribuídos sobre o solo de uma região de floresta com área plana de  $100\text{ m} \times 100\text{ m}$  (dez mil metros quadrados). A figura 3.3 representa uma ilustração para o modelo da floresta. Por motivo de simplificação não foram considerados aspectos como relevo ou quaisquer objetos que representem obstáculos que venham a limitar a área de percepção dos sensores e o raio de comunicação entre estes. Ou seja, uma vez distribuídos, cada sensor está apto ao monitoramento e à comunicação. Desta forma, apenas as características técnicas do fotossensor e do rádio de transmissão/recepção são consideradas como os fatores determinantes das áreas de percepção e comunicação dos sensores.



Figura 3.3: Floresta monitorada

### 3.3.2 Fenômeno em observação

Utilizando campos gaussianos apresentados na Seção 2.4.1, modelamos o fenômeno ou processo natural observado pela rede de sensores como sendo a iluminação incidente no solo da floresta, num dado instante, decorrente dos raios solares filtrados pelas copas das árvores. Os dados gerados a partir do modelo são registrados numa matriz de 10000 pixels ( $100 \times 100$ ), definida como a amostra  $f$ . Os valores dos pixels variam de acordo com a intensidade de iluminação incidente. A correlação entre os valores de  $f$  está relacionada com a densidade da folhagem das árvores. Desta forma, através do emprego dos campos

gaussianos, assumindo a função de covariância  $\exp(-\mathbf{x}^s)$ ,  $s > 0$ , e variando o parâmetro escala  $s$  que caracteriza este modelo, podemos obter diferentes granularidades de iluminação.

A figura 3.4 ilustra exemplos dos quatro tipos de granularidades obtidas para a iluminação incidente no solo da floresta ao variarmos o parâmetro escala nos valores 5, 10, 15 e 20.

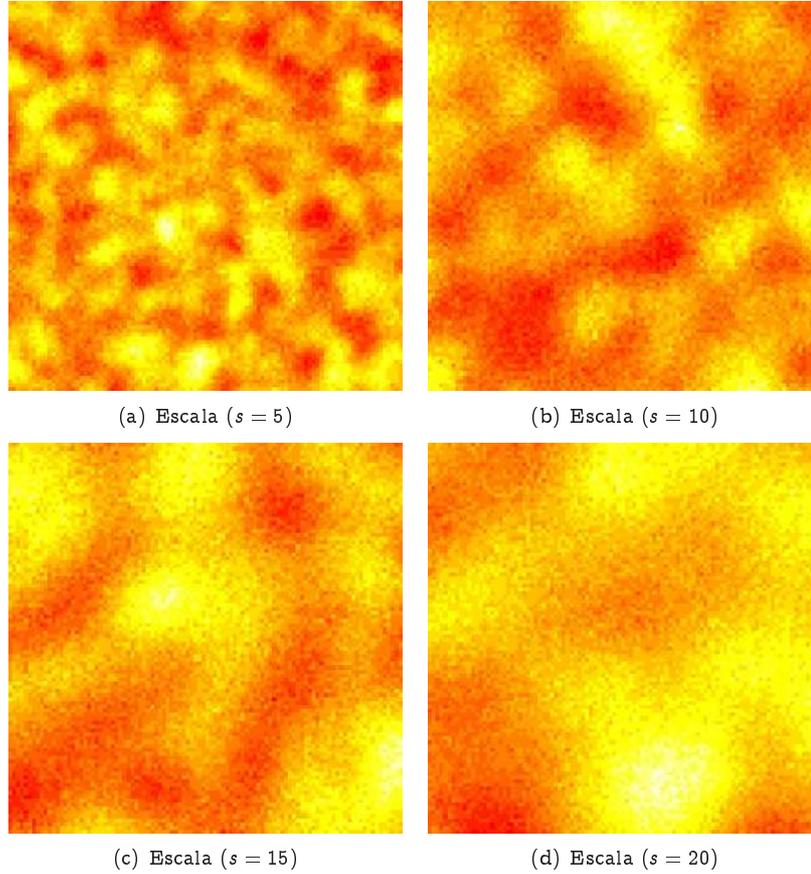


Figura 3.4: Fenômeno iluminação

As ocorrências do campo gaussiano são geradas pela plataforma R, que opera com dados em precisão dupla e, portanto, cada observação gerada emprega uma palavra de oito bytes. Esses dados são entrada para outros algoritmos que utilizam dados em precisão simples e, com isso, o resto do processamento é feito sobre palavras de quatro bytes.

Embora neste trabalho consideremos apenas campos gaussianos, a proposta pode ser estendida naturalmente para outros modelos contínuos e, mais geralmente, para outros tipos de dados. Outros modelos contínuos podem descrever dados com assimetria, como é o caso das distribuições gama e  $\mathcal{G}$  (ver Bustos et al., 2001). Outros tipos de dados a serem considerados são os discretos, que fornecem modelos naturais para processos que envolvem contagem de eventos. A metodologia aqui proposta pode, ainda, ser aplicada a dados multivariados mistos, isto é, para aquelas situações que envolvem várias medidas tanto contínuas quanto discretas.

### 3.3.3 Distribuição dos sensores

A distribuição espacial dos sensores na região monitorada é descrita neste trabalho utilizando-se modelos estocásticos do tipo processos pontuais, apresentados na Seção 2.4.2. Para tal fim, propomos um processo pontual  $C(n, a)$  que descreve a localização espacial de  $n$  pontos através de um único parâmetro real,  $a$ , capaz de descrever as situações de interesse para o nosso estudo.

Mapeando a região sob monitoração, definimos uma região  $E = [0, 100]^2$  sobre a qual iremos contruir nosso processo pontual. Além disto, estabelecemos a *intensidade*  $\eta$  dos processos Poisson com sendo  $\eta = 1$ .

Nosso processo pontual  $C$  é construído através da composição de três outros processos pontuais derivados do processo Poisson. Tais processos pontuais são:

1.  $B(n, E)$ , processo pontual Binomial definido na região  $E$  (ver definição 16, na página 12);
2.  $M = (n, p, E)$ , processo pontual Matérn's SSI com parâmetro de exclusão  $r = 5 - 5p$  (definição 20, na página 13);
3.  $S(n, a, \eta, E, E')$ , processo pontual composto por dois processos Poisson, um aplicado com intensidade  $a\eta$  sobre uma área alvo  $E' \subset E$ , e outro com intensidade  $\eta$  aplicado sobre a área  $E \setminus E'$ ;

Omitindo, por simplificação, os parâmetros  $\eta$ ,  $E$  e  $E'$ , definimos o nosso processo pontual  $C(n, a)$  da seguinte forma

$$C(n, a) = \begin{cases} M(n, e^a) & \text{if } a < 0 \\ B(n) & \text{if } 0 \leq a \leq 1 \\ S(n, a) & \text{if } a > 1. \end{cases} \quad (3.1)$$

Manipulando os parâmetros ( $n$  e  $a$ ) desse modelo observamos variações no comportamento da distribuição. Para o monitoramento de florestas, estamos interessados basicamente nas seguintes variações quanto a distribuição dos sensores: processos atrativo ( $a > 1$ ), independente ( $a \in [0, 1]$ ), repulsivo ( $a < 0$ ) e regular ( $a = -\infty$ , denotando a repulsividade máxima entre os  $n$  pontos).

Uma vez que tenham sido distribuídos os sensores, o sensor  $S_i$  está localizado em  $(x_i, y_i) \in [0, 100]^2$ .

O processo regular é utilizado para modelar a distribuição totalmente controlada e equidistante dos sensores, como se tivessem sido posicionados sobre as intersecções de uma malha. A figura 3.5 ilustra uma distribuição regular de cem sensores na região da floresta monitorada.

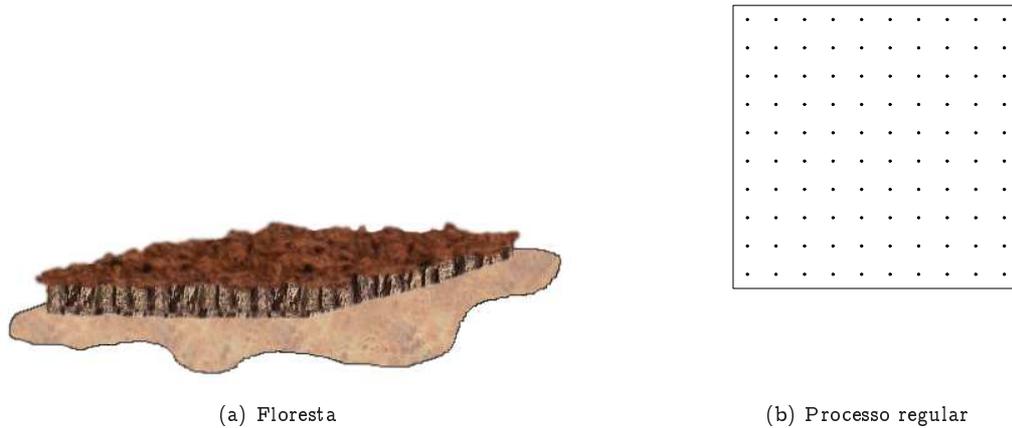


Figura 3.5: Distribuição - processo regular

O processo repulsivo é utilizado para modelar a distribuição dos sensores sob condições de controle incompleto, como por exemplo ao lançarmos gradativamente os sensores a partir de um helicóptero sobrevoando a área num plano de vôo de altura constante. Quanto mais próximo do dossel da floresta maior esse controle na distribuição dos sensores. Na figura 3.6 ilustramos a distribuição dos sensores em um plano de vôo bem próximo do dossel da floresta.

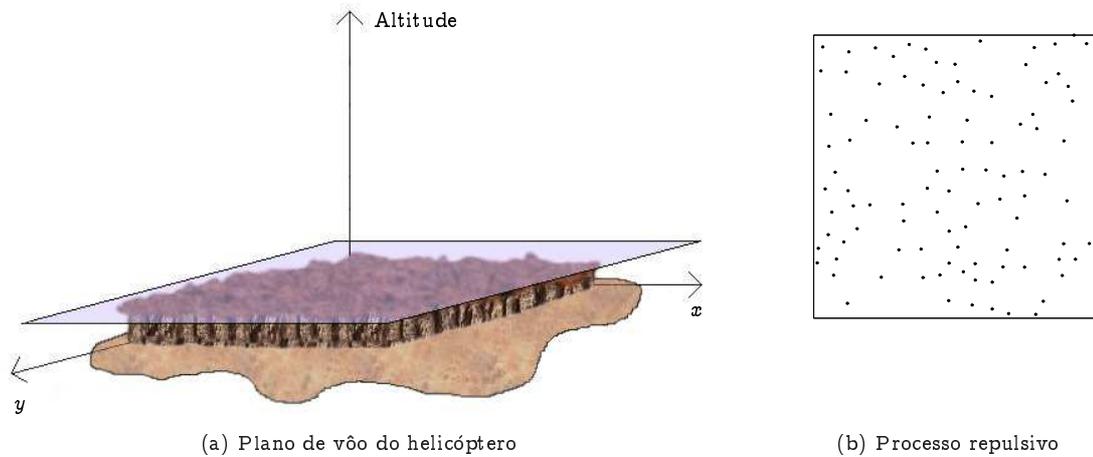


Figura 3.6: Distribuição - processo repulsivo

O controle na distribuição irá diminuir à medida que a altitude do plano de voo aumentar. Na figura 3.7 vemos um processo repulsivo com uma maior perda de controle na distribuição dos sensores. Percebemos na figura 3.6(b) um maior espalhamento dos sensores ao compará-la com a figura 3.7(b).

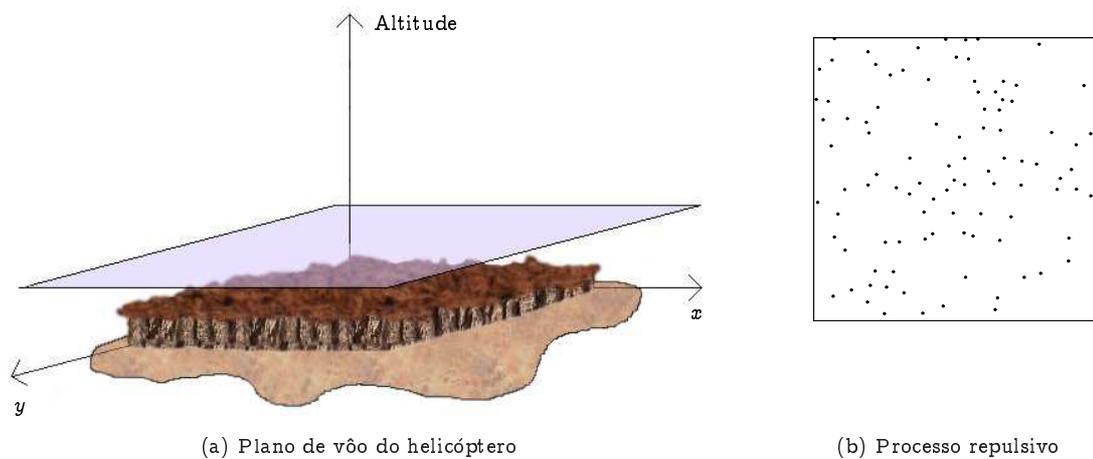


Figura 3.7: Distribuição - processo repulsivo

Utilizamos o modelo atrativo ao modelar, por exemplo, a distribuição dos sensores resultante do lançamento maciço dos sensores a partir de um avião cruzando a área num plano de voo de altura constante. Quanto maior a proximidade entre o plano de voo e o dossel da floresta, maior a característica atrativa do processo, resultando numa maior concentração dos sensores numa certa parte da área. Na figura 3.8 ilustramos a distribuição dos sensores lançados, num dado instante, a partir de um avião cruzando a floresta em plano de voo bem próximo ao seu dossel com o objetivo de distribuir o máximo de sensores numa área alvo, neste caso o canto inferior esquerdo.

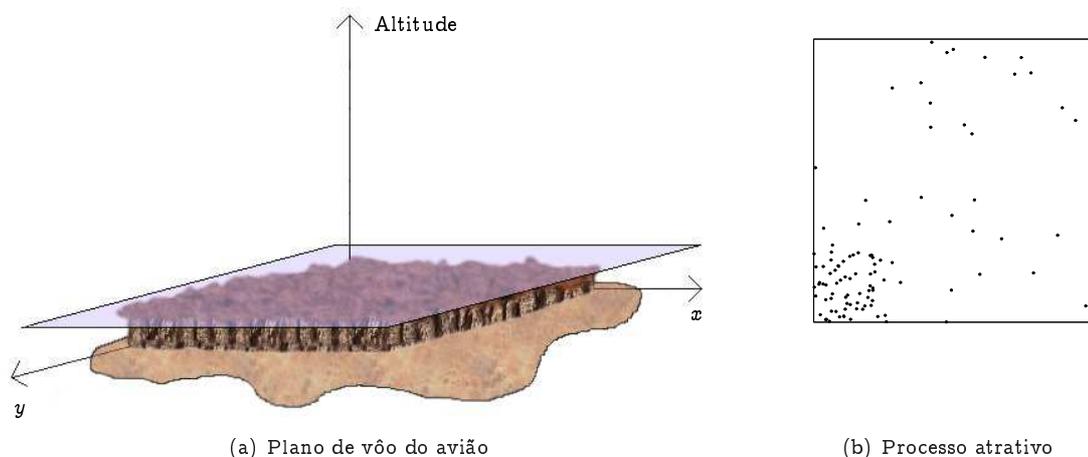


Figura 3.8: Distribuição - processo atrativo

Da mesma forma que o processo repulsivo, no modelo atrativo o controle na distribuição irá diminuir à medida que a altitude do plano de vôo aumentar. Ao ilustrarmos na figura 3.9 uma distribuição em plano de vôo mais elevado, percebemos um menor controle na distribuição dos sensores.

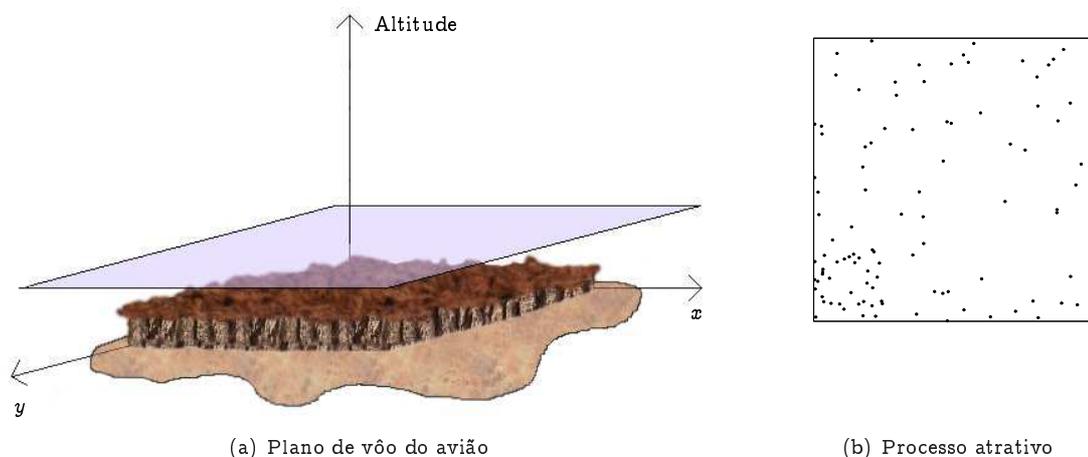


Figura 3.9: Distribuição - processo atrativo

Pela figura 3.9(b) constatamos uma menor densidade na distribuição dos sensores na área alvo considerada na região da floresta, quando comparada com a figura 3.8(b).

O processo independente modela a distribuição em condições de aleatoriedade total da localização como, por exemplo, o que ocorre ao lançarmos os sensores de um helicóptero ou mesmo de um avião a partir de um plano de vôo muito distante do dossel da floresta. A partir de certa altitude não mais haverá controle na distribuição dos sensores, não mais ocorrendo os comportamentos repulsivos ou atrativos como ilustrados anteriormente. Esta condição de aleatoriedade ou independência na distribuição dos sensores é ilustrada na figura 3.10.

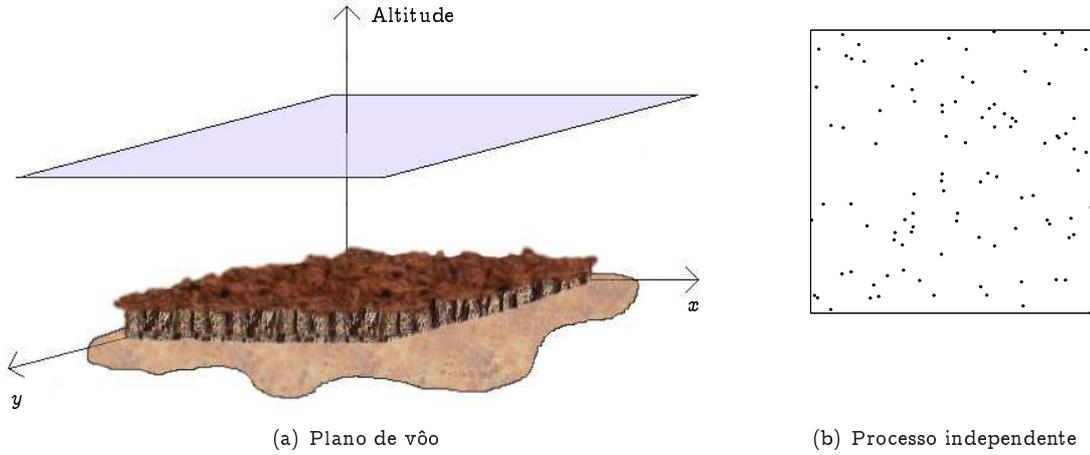


Figura 3.10: Distribuição - processo independente

### 3.3.4 Sensores

Propomos neste trabalho duas abstrações para modelar os dois tipos de sensores utilizados nas simulações. Esses tipos de sensores diferem exclusivamente quanto à área de percepção e quanto à área de comunicação.

Independentemente do tipo de modelo e conforme a distribuição dos sensores definida na Seção 3.3.3, o sensor  $S_i$  está localizado em  $(x_i, y_i) \in [0, 100]^2$ .

Na primeira abstração, à qual sempre nos referiremos como *tipo 1*, as características de percepção e de comunicação dos sensores são definidas com base nas células e diagrama de Voronoi induzidos pela localização dos sensores. Na figura 3.11(a) ilustramos o diagrama de Voronoi construído a partir da distribuição de seis sensores:  $S_1, \dots, S_6$ . Cada célula de Voronoi representa a área de percepção  $A_i$  do sensor  $S_i$ . Muito embora esta abstração defina apenas um tipo de sensor, as dimensões da área de percepção de cada sensor variam de acordo com as dimensões da sua célula de Voronoi.

Desta forma, nesta abstração a função característica do sensor  $S_i$  é definida por uma função indicadora  $\kappa_i : \mathbb{R}^2 \rightarrow \mathbb{R}_+$  tal que

$$\kappa_i(x, y) = \mathbb{1}_{V_i}(x, y) \quad (3.2)$$

onde  $V_i$  é a célula de Voronoi associada ao sensor  $S_i$ , e  $\mathbb{1}_A(x)$  é a função indicadora do conjunto  $A$ , isto é,  $\mathbb{1}_A(x) = 1$  se  $x \in A$ , e  $\mathbb{1}_A(x) = 0$  caso contrário. Desta maneira, a equação (3.2) modela um sensor que possui a mesma sensibilidade em toda a sua área de cobertura, e para o qual a área de cobertura é a região do espaço mais próxima dele do que de qualquer outro sensor. Neste caso, portanto, não há possibilidade de sobreposição de áreas de cobertura nem de regiões do espaço não cobertas por algum sensor.

A comunicação direta entre sensores é possível com base na relação de vizinhança entre as células de Voronoi, de modo que dois sensores são vizinhos sempre que suas células compartilhem de pelo menos um vértice. A figura 3.12(a) ilustra a idéia de que o sensor  $S_1$  pode se comunicar diretamente com os sensores  $S_2$  e  $S_4$  uma vez que ele mantém com estes uma relação de vizinhança. Assim sendo, nesta primeira abstração, há sempre conectividade entre quaisquer par de sensores através de algum número de sensores intermediários.

Na segunda abstração, a área de percepção de cada sensor é caracterizada pela função de resposta radial do seu fotossensor, definida como a função indicadora de uma área circular em volta do sensor. Assim, assumindo um único modelo de fotossensor e como consequência uma única função de resposta radial, modelamos as áreas de percepção  $A_i$  do sensor  $S_i$  como sendo discos de áreas iguais definidos pelo mesmo raio  $r_p$  de percepção.

A função característica do sensor  $S_i$  nesta abstração é definida por uma função  $\kappa_i : \mathbb{R}^2 \rightarrow \mathbb{R}_+$  conforme a seguinte equação:

$$\kappa_i(x, y) = \begin{cases} 1 & \text{se } \sqrt{(x_i - x)^2 + (y_i - y)^2} \leq r_p, \\ 0 & \text{caso contrário.} \end{cases} \quad (3.3)$$

A equação (3.3) modela a situação de um sensor que possui a mesma sensibilidade em toda a sua área de cobertura, e para o qual a área de cobertura é um círculo de raio  $r_p$  centrado no sensor. Neste caso, mais realista do que o descrito pela equação (3.2), há possibilidade de sobreposição de áreas de cobertura e de existirem regiões do espaço não cobertas.

Considerando um mesmo modelo de hardware de comunicação para este tipo de sensores, assumimos suas áreas de comunicação como sendo circulares e de dimensões definidas pelo raio do rádio de transmissão/recepção  $r_c$ . Dependendo do valor deste raio e da distribuição espacial dos sensores, poderá haver sensores ou grupos de sensores impossibilitados de se comunicarem com os demais. Assim sendo, diferentemente da primeira abstração, não é garantida a conectividade do grafo na segunda abstração.

Na figura 3.11(b) ilustramos os mesmos seis sensores e suas áreas de percepção para a segunda abstração. A comunicação entre dois sensores é possível sempre que um estiver no raio de ação do rádio de transmissão/recepção do outro. Ilustramos na figura 3.12(b) a possibilidade de comunicação direta entre o sensor  $S_1$  e os outros presentes em seu raio de comunicação, neste caso os sensores  $S_2$  e  $S_4$ . Ao nos referirmos a este modelo de sensores usaremos o termo *tipo 2*.

Ressaltamos que nunca temos numa mesma simulação sensores dos dois tipos, ou seja, ou estamos tratando com sensores *tipo 1* ou com sensores *tipo 2*.

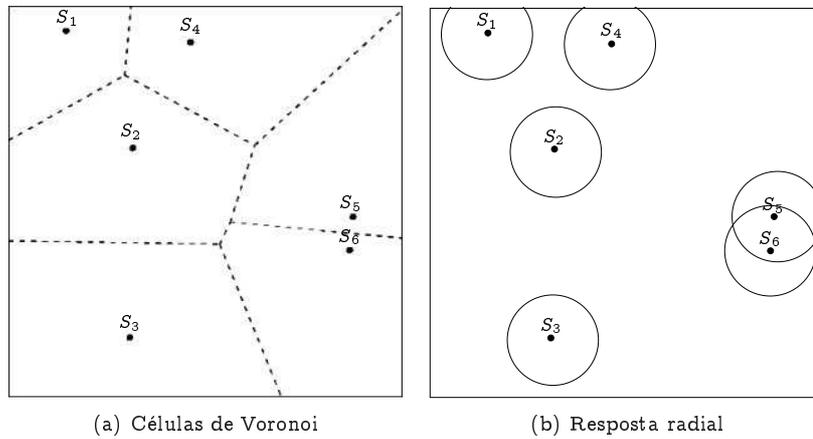


Figura 3.11: Área de percepção - Função característica

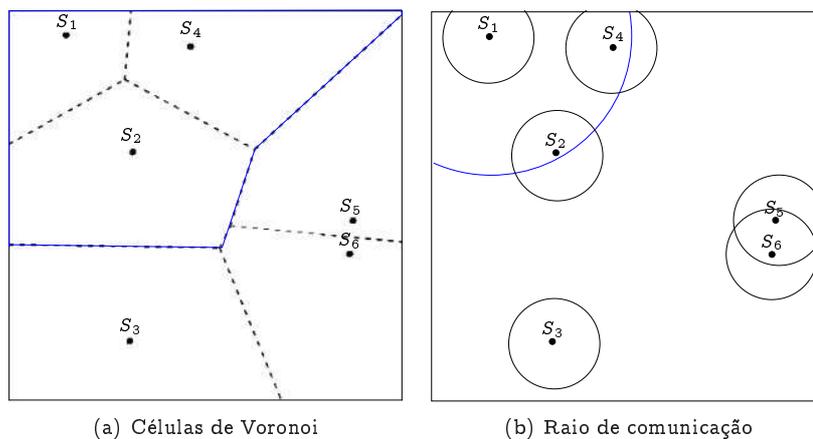


Figura 3.12: Área de comunicação - Relação de vizinhança

Ao escolhermos uma destas duas abstrações estamos definindo sob que condições as simulações estão sendo realizadas quanto à amostragem e clusterização. Assim, utilizamos os dois modelos de sensores objetivando avaliar a qualidade do processo de reconstrução em duas situações paralelas e de interesse, descritas a seguir.

### 3.3.4.1 Situação 1: células de Voronoi como área de percepção

Num primeiro momento, as simulações são realizadas utilizando-se os sensores *tipo1* nos moldes do estudo apresentado em Frery et al. (2008) considerando uma cobertura total da área sendo monitorada, além de desconsiderar sobreposições entre áreas de percepção de sensores vizinhos. Para isto, uma vez distribuídos os sensores por um processo pontual, construímos um diagrama de Voronoi com base nas coordenadas dos sensores. Utilizando esse diagrama, estamos particionando por completo a área de interesse em tantas células quanto o número de sensores. Objetivamos com esta primeira etapa, ao desconsiderarmos os aspectos relacionados à sobreposição e falta de cobertura, mostrar o impacto dos três fatores na qualidade de reconstrução dos dados: a granularidade do processo sob estudo, a distribuição espacial dos sensores e o protocolo de clusterização e agregação de dados. Sempre que desejarmos nos referir a este tipo de simulação usaremos o termo *situação1*.

### 3.3.4.2 Situação 2: resposta radial como área de percepção

Num segundo momento, considerando alguns aspectos e limitações inerentes às redes de sensores e tecnologias relacionadas, procedemos com novas simulações buscando uma maior aproximação com a realidade. Primeiramente, passamos a assumir o modelo de sensor *tipo2*, cuja área de percepção é caracterizada pela função de resposta radial do seu fotossensor, sendo então circular. Como consequência desta nova definição, surgem três novos ingredientes a serem considerados: (i) a possibilidade de áreas sem cobertura pela rede de sensores, (ii) a possibilidade de sobreposição entre as áreas de percepção de sensores espacialmente próximos, e (iii) a possibilidade de um ou mais sensores ficarem isolados do resto, ou seja, sem comunicação com os demais. A inclusão destes aspectos representa um impacto direto na avaliação da qualidade do processo de reconstrução, sendo necessário levarmos em conta cada uma de suas peculiaridades. Como anteriormente, utilizaremos o termo *situação2* sempre que nos referirmos a este tipo de simulação.

Na subseções 3.3.5 e 3.3.6 detalhamos nossas modelagens para os processos de amostragem e de clusterização respectivamente, utilizando ambas as situações.

## 3.3.5 Amostragem

Uma vez que tenham sido gerados os dados de iluminação  $f$  sobre a região de floresta a partir do nosso modelo “Fenômeno” definido na Seção 3.3.2, bem como distribuídos os  $n$  sensores por um processo pontual  $C(n, a)$  anteriormente descrito na abstração “Distribuição dos sensores” (ver Seção 3.3.3), dar-se-á início ao processo individual de amostragem dos sensores.

Para qualquer tipo de sensor modelado neste trabalho (ver Seção 3.3.4), a amostragem de  $f$  pelo sensor  $S_i$  é completamente especificada pela função característica  $\kappa_i$  desse sensor e assume a forma geral

$$\Psi_{1S_i} = \int f \kappa_i. \quad (3.4)$$

A figura 3.13(a) ilustra o mapeamento do diagrama de Voronoi representando as áreas de percepção de seis sensores *tipo1* sobre a matriz de 10000 pixels ( $100 \times 100$ ) representando os 10000 valores ou observações da amostra  $f$  de iluminação sobre a região monitorada.

Na figura 3.13(b) ilustramos o mapeamento das áreas de percepção de seis sensores *tipo2* sobre a mesma matriz da dados.

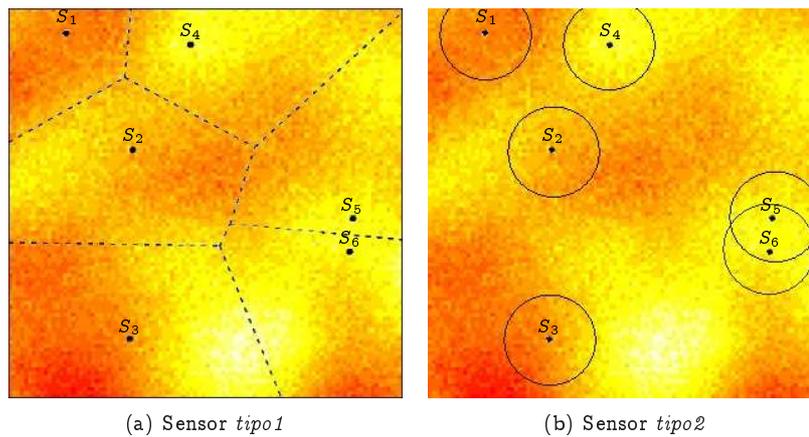


Figura 3.13: Iluminação e área de percepção

A seguir detalhamos o processo de amostragem para cada uma das duas situações definidas na Seção 3.3.4.

### 3.3.5.1 Amostragem - *situação1*

Na *situação1*, conforme sua definição, o processo de amostragem é realizado por sensores *tipo1*. A área de percepção  $A_i$  de um sensor  $S_i$  deste tipo é definida como a área de célula de Voronoi a ele associada.

Neste situação, a cobertura da área monitorada é total e não há sobreposição de áreas de percepção.

Cada uma das 10000 observações ou pixels da matriz representativa de  $f$  é mapeada para uma das células de Voronoi associada a um dos sensor  $S_i$  sendo computada para o cálculo da amostragem  $\Psi_{1S_i}$  deste sensor.

A figura 3.14 ilustra a amostragem  $\Psi_1$  de  $f$  pela rede de seis sensores do *tipo1*. Cada sensor sumariza em um único valor os dados de iluminação por ele percebidos. Nesta e nas próximas figuras, o valor resultante da amostragem realizada por cada sensor é simbolizado como um ponto colorido.

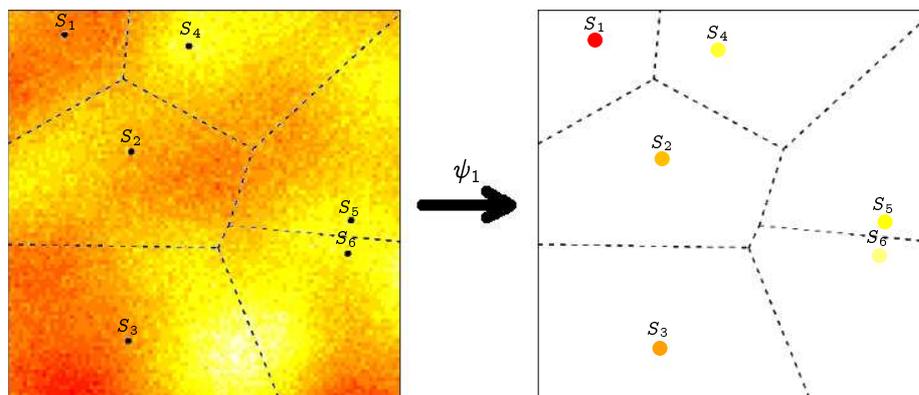


Figura 3.14: Amostragem  $\Psi_1$  - Células de Voronoi

### 3.3.5.2 Amostragem - *situação2*

Nesta segunda situação, pelo fato dos sensores *tipo2* apresentarem áreas de percepção circulares definidas pela função de resposta radial dos seus fotossensores, não mais está garantida a cobertura total da região sob monitoração nem a ausência de sobreposição.

Pela limitação de cobertura, nem todas as observações da matriz de  $f$  são mapeadas para as áreas de percepção dos sensores, não sendo assim mensuradas. Pela ocorrência de sobreposição de áreas de percepção de sensores vizinhos, algumas observação são computadas no cálculo de amostragem de mais de um sensor.

Na figura 3.15 ilustramos a amostragem  $\Psi_1$  dos dados de iluminação pela rede de seis sensores *tipo2*. Igualmente, cada sensor sumariza em um único valor os dados das observações de  $f$  por ele percebidas.

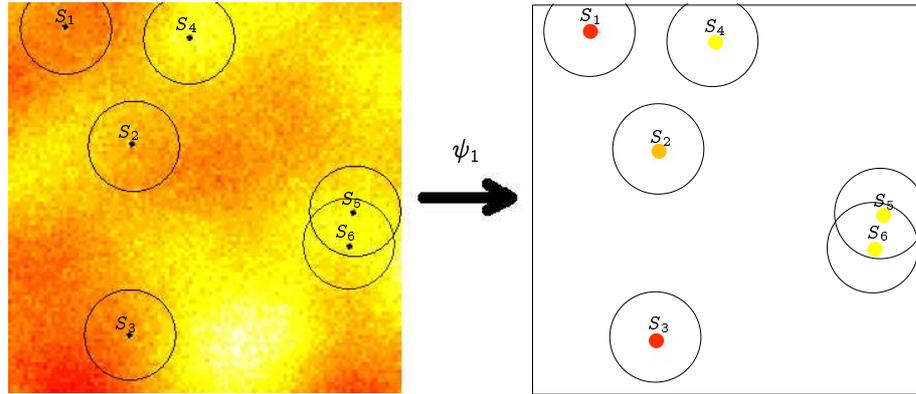


Figura 3.15: Amostragem  $\Psi_1$  - Resposta radial

Ao compararmos visualmente a amostragem entre as duas situações, considerando a sumarização segundo a equação (3.4) (página 24) para as diferentes áreas de percepção definidas pelas equações (3.2) e (3.3), percebemos que o ponto colorido simbolizando a amostragem do sensor  $S_3$  da figura 3.15 apresentase numa cor mais escura que o ponto colorido símbolo do valor amostrado pelo mesmo sensor na figura 3.14.

### 3.3.6 Clusterização

Em nossas simulações o processo de clusterização  $\Psi_2$  modela o agrupamento dos sensores em um número desejável de *clusters*.

O processo de clusterização, ou agrupamento, pode ser formalizado a partir do conjunto de sensores a ser agrupado  $\{S_1, \dots, S_n\}$ , com  $n \geq 2$ , pela função  $\Psi_2$  definida sobre os índices  $\Psi_2: \{1, \dots, n\} \rightarrow \{C_1, \dots, C_N\}$ , onde  $N$  é o número de *clusters* ou grupos e  $C_1, \dots, C_N \subset \{1, \dots, n\}$  formam uma partição de elementos não vazios, isto é, valem as seguintes propriedades

1.  $C_i \neq \emptyset$  para todo  $1 \leq i \leq N$ ,
2.  $C_i \cap C_j = \emptyset$  toda vez que  $i \neq j$ ,
3.  $\cup_{i=1}^N C_i = \{1, \dots, n\}$ .

Neste trabalho consideramos a emprego dos dois diferentes protocolos de clusterização LEACH (Heinzelman et al., 2000) e SKATER (Assunção et al., 2006). Expomos algumas considerações de implementação nas Seções 3.6.3.8 e 3.6.3.10, respectivamente.

O protocolo LEACH agrupa os sensores nos *clusters* em duas etapas. Na primeira, ele elege aleatoriamente dentre os sensores um *cluster head* (CH) para cada *cluster*. Em nossas simulações, esta escolha aleatória respeita uma restrição que define qual a distância mínima entre os CH. Em seguida ele associa cada um dos sensores restantes ao CH mais próximo com base na informação de vizinhança espacial. Cumpridas estas etapas a clusterização está concluída. Este protocolo assume que sensores vizinhos amostram dados correlacionados.

No protocolo SKATER o CH não desempenha um papel fundamental na escolha dos sensores membros. Usando tanto a informação de vizinhança espacial quanto os valores amostrados por cada sensor, este protocolo define os *clusters* com base na construção e no particionamento de uma árvore de mínimo custo (AMC). Nesta árvore, os nós representam os sensores com seus valores de amostragem, as arestas as relações de vizinhança entre sensores e os pesos destas arestas as medidas de dissimilaridades entre os valores amostrados pelos sensores vizinhos obtidas utilizando-se a distância euclidiana. Este protocolo assegura que os membros de um *cluster* amostram dados o mais correlacionados possível.

A seguir detalhamos o processo de clusterização empregado na *situação1* e na *situação2*.

#### 3.3.6.1 Clusterização - *situação1*

Nesta situação a relação de vizinhança entre os sensores utilizada para a formação dos *clusters* varia de acordo com o protocolo de clusterização.

No LEACH, um sensor qualquer é considerado vizinho do CH mais próximo e bem como dos outros sensores associados a este CH.

No SKATER, dois sensores são vizinhos sempre que suas células de Voronoi compartilhem de um mesmo vértice.

A figura 3.16 ilustra a clusterização  $\Psi_2$  pelo protocolo LEACH dos seis sensores *tipo 1* em três *clusters* para a *situação 1*. Após ter escolhido aleatoriamente os sensores  $S_1$ ,  $S_2$  e  $S_6$  como os CHs dos *clusters*  $C_1$ ,  $C_2$  e  $C_3$ , respectivamente, o protocolo inicia a formação dos *cluster* associando cada um dos sensores restantes ao CH mais próximo. Concluída a clusterização, o *cluster*  $C_1$  contém como membro o sensor  $S_1$ , o *cluster*  $C_2$  apresenta  $S_2$ ,  $S_3$  e  $S_4$  como seus integrantes e o *cluster*  $C_3$  agrupa os demais sensores  $S_5$  e  $S_6$ .

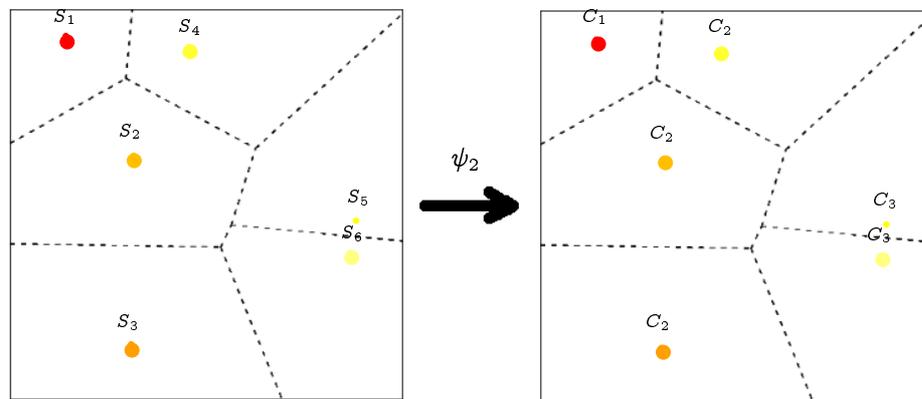


Figura 3.16: Clusterização  $\Psi_2$  - *Situação 1* - Protocolo LEACH

A figura 3.17 ilustra a clusterização  $\Psi_2$  pelo protocolo SKATER dos mesmos seis sensores *tipo 1* em três *clusters* para a *situação 1*. O *cluster*  $C_1$  contém como integrante apenas o sensor  $S_1$ , o *cluster*  $C_2$  possui  $S_2$  e  $S_3$  entre seus membros e o *cluster*  $C_3$  agrupa os demais sensores  $S_4$ ,  $S_5$  e  $S_6$ . Nessa figura percebemos uma maior correlação entre os dados amostrados pelos membros dos três *clusters* quando comparamos com a figura 3.16.

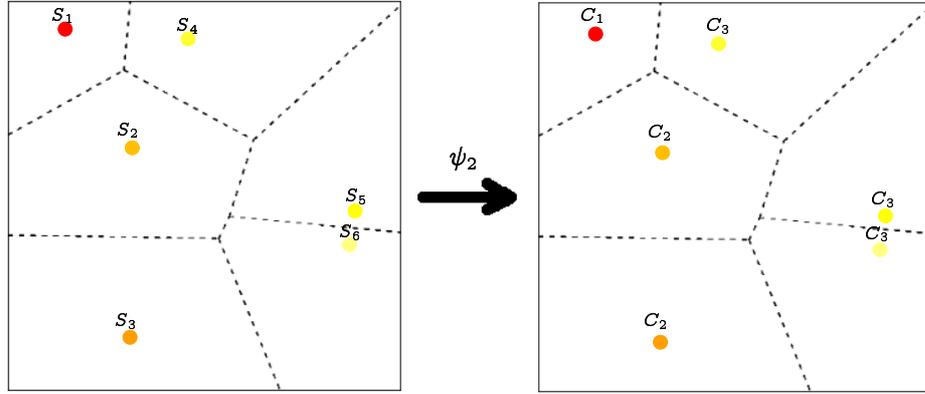


Figura 3.17: Clusterização  $\Psi_2$  - *Situação1* - Protocolo SKATER

### 3.3.6.2 Clusterização - *situação2*

Nesta situação, para o SKATER, em virtude das características de comunicação dos sensores *tipo2* descritas na Seção 3.3.4, a relação de vizinhança entre estes sensores utilizada para a formação dos *clusters* é definida com base no raio de comunicação  $r_c$ . Desta forma, dois sensores são considerados vizinhos sempre que a distância entre eles for menor ou igual ao valor de  $r_c$ .

O tamanho do raio de comunicação  $r_c$  depende das características técnicas do rádio dos sensores. Em nossas simulações, o raio de comunicação  $r_c$  é definido de forma que nenhum sensor ou grupo de sensores estejam impossibilitados de comunicar-se com os demais sensores (ver as considerações de implementação na Seção 3.6.3.6). Ao adotarmos um raio de comunicação com essas garantias de comunicação entre os sensores da rede, estamos simplificando nossas simulações eliminando a possibilidade de isolamento de sensores, apontada na Seção 3.3.4.2 (página 24).

Da mesma forma que ocorre na *situação1*, na *situação2* o protocolo LEACH agrupa os sensores aos CHs mais próximos, independentemente da relação de similaridade entre os valores por eles amostrados. Na figura 3.18, ilustramos a formação  $\Psi_2$  dos *cluster* pelo LEACH para a *situação2*. Neste caso, o protocolo elegeu os sensores  $S_4$ ,  $S_3$  e  $S_5$  como os CHs dos *clusters*  $C_1$ ,  $C_2$  e  $C_3$ , respectivamente. Três sensores,  $S_1$ ,  $S_2$  e  $S_4$ , são agrupados como membros do *cluster*  $C_1$ , enquanto  $S_3$  compõe sozinho o  $C_2$ , e  $S_5$  e  $S_6$  formam o *cluster*  $C_3$ .

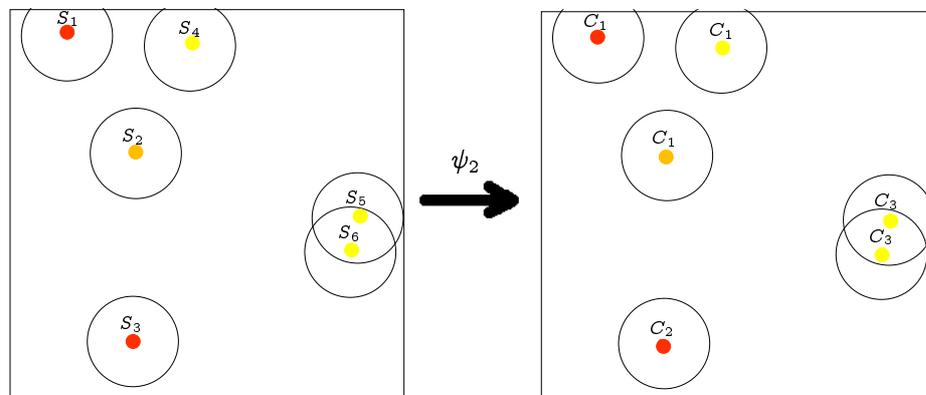


Figura 3.18: Clusterização  $\Psi_2$  - *Situação2* - Protocolo LEACH

A figura 3.19 ilustra clusterização  $\Psi_2$  pelo protocolo SKATER dos mesmos seis sensores *tipo2* em três *clusters* para a *situação2*. O *cluster*  $C_1$  contém como integrantes os sensores  $S_1$  e  $S_3$ , o *cluster*  $C_2$  possui apenas  $S_2$  como membro e o *cluster*  $C_3$  agrupa os demais sensores  $S_4$ ,  $S_5$  e  $S_6$ . Diferentemente do LEACH no qual a escolha dos CHs desempenha papel decisivo na formação dos *cluster*, o SKATER formará *clusters* considerando a maior correlação possível entre os dados amostrados pelos sensores.

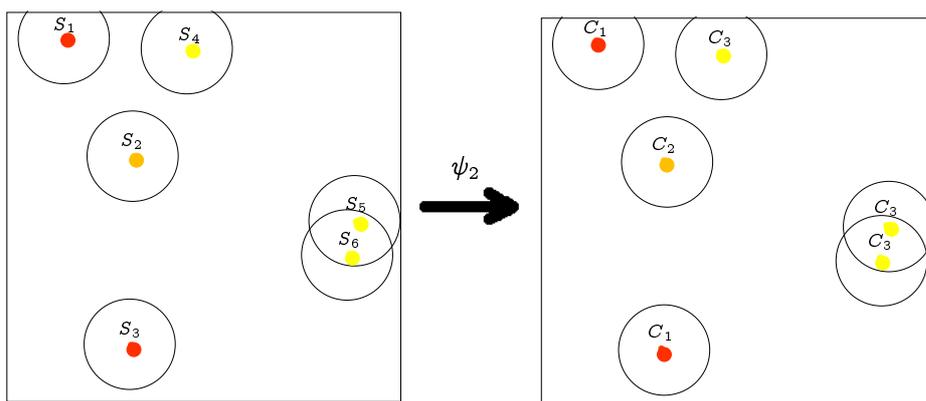


Figura 3.19: Clusterização  $\Psi_2$  - *Situação2* - Protocolo SKATER

### 3.3.7 Agregação

Concluído o agrupamento dos sensores pelo processo de clusterização, são realizadas as operações de fusão de dados em cada *cluster*.

Considere a seguir apenas o *cluster*  $C_j$ , e seus nós membros  $\{S_i : S_i \text{ faz parte de } C_j\}$ . Cada sensor membro  $S_i$  envia o resultado da sua amostragem  $\Psi_{1S_i}$  (ver equação 3.4) para o *cluster head*  $CH_j$ , que é um dos nós que compõem o *cluster*  $C_j$ , isto é, o *cluster head*  $CH_j \in \{S_i : S_i \text{ faz parte de } C_j\}$ . Um vez que tenham sido recebidos todos os dados dos sensores membros,  $CH_j$  processa a fusão desses dados; no nosso caso, o operador de agregação é a média dos valores observados. Desta forma, a agregação em cada *cluster*  $\Psi_{3C_j}$  é definida pela equação (3.5)

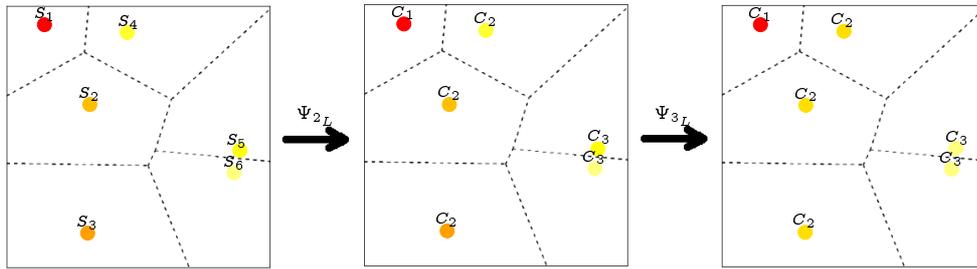
$$\Psi_{3C_j} = \frac{1}{N_j} \sum_{i=1}^{N_j} \Psi_{1S_i} \quad (3.5)$$

onde  $N_j$  representa o número de sensores membros no *cluster*  $C_j$  incluindo o  $CH_j$ .

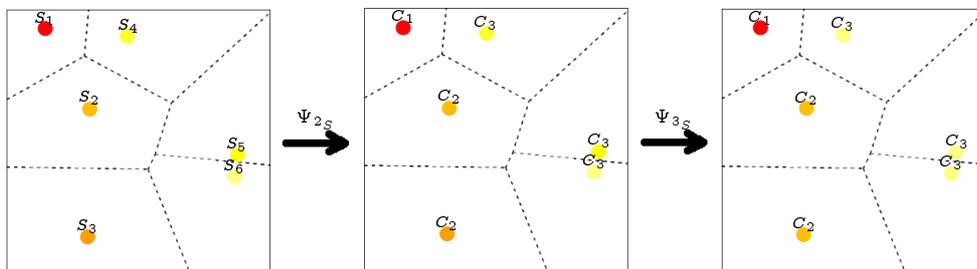
O único operador de agregação utilizado neste trabalho é a média.

Os resultados das agregações de todos os *clusters* são enviados para a estação base pelos respectivos *cluster heads*. Além do valor resultante da agregação dos dados são também enviadas as informações de localização dos membros de cada *cluster*.

A figura 3.20 ilustra, para o LEACH e para o SKATER, os resultados das operações de clusterização  $\Psi_2$  e de agregação  $\Psi_3$  realizadas após a operação de amostragem pela rede de seis sensores. Percebemos pela figura 3.20(b) que na operação de clusterização realizada pelo SKATER  $\Psi_{2S}$ , o sensor  $S_4$  passa a pertencer ao *cluster*  $C_3$ . A clusterização pelo SKATER  $\Psi_{2S}$  formou *clusters* mais homogêneos que os obtidos pela clusterização por LEACH  $\Psi_{2L}$  ilustrada na figura 3.20(a), e como consequência disto o SKATER obteve um melhor resultado para o processo de agregação  $\Psi_{3S}$ .



(a) LEACH - Cluster heads  $S_1$ ,  $S_2$  and  $S_6$



(b) SKATER

Figura 3.20: Clusterização/agregação a partir do LEACH e do SKATER na *situação 1*

### 3.3.8 Reconstrução

Os dados de iluminação  $f$  percebidos, processados e enviados pela rede de sensores para a estação base, em conjunto com as informações de localização dos sensores, são então disponibilizados aos usuários da rede para utilizá-los da forma que lhes convier.

Estes dados estão disponíveis para os interessados na reconstrução do fenômeno sob observação. Os dados são a entrada do processo de reconstrução  $\Psi_4$  que proverá como resultado os dados de reconstrução de iluminação  $\hat{f}$ .

Da mesma forma que  $f$ , os dados de reconstrução  $\hat{f}$  são registrados numa matriz de 10000 pixels ( $100 \times 100$ ). Os valores dos pixels são definidos de acordo com a técnica de interpolação utilizada pelo processo de reconstrução.

Neste trabalho, modelamos o processo de reconstrução utilizando duas técnicas de interpolação: (i) diagrama de Voronoi, denotado  $\Psi_{4V}$  e (ii) Kriging, denotado  $\Psi_{4K}$ .

Ao utilizarmos o diagrama de Voronoi como o processo de reconstrução  $\Psi_{4V}$ , atribuímos a todos pixels da reconstrução  $\hat{f}$  da célula de Voronoi associada ao sensor  $S_i$  o mesmo valor informado por  $S_i$  (ver detalhes de implementação mais adiante na Seção 3.6.3.12, página 44).

No processo de reconstrução por Kriging,  $\Psi_{4K}$ , a matriz de reconstrução  $\hat{f}$  é gerada por interpolação através modelo de Kriging *Simple*. Optamos por este modelo, pelo fato de ele ser matematicamente o mais simples dentre os tipos clássicos de Kriging implementados em pacotes da plataforma computacional R utilizada em nossas simulações (ver detalhes na Seção 3.6.3.13, página 44).

Sob o ponto de vista do projeto de redes de sensores, os resultados do processo de reconstrução poderão ser utilizados pelos projetistas com o intuito de avaliar os diversos aspectos da modelagem da rede. Desta forma, a depender do interesse, a avaliação do projeto poderá ser realizada no contexto global ou mesmo particular dos componentes.

Considerando o nosso modelo genérico, composto pelos diversos elementos ou componentes modelados na Seção 3.3 e ilustrado na figura 3.2, propomos a aplicação do processo de reconstrução a partir de três conjuntos de dados: (i) conjunto de dados representando as amostragens individuais dos sensores ainda não clusterizados ( $\Psi_1$ ), (ii) conjunto resultante da agregação dos dados amostrados por sensores clusterizados pela técnica de LEACH ( $\Psi_{3L}$ ) e (iii) conjunto resultante da agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3S}$ ). Com isto, ao avaliarmos os dados de reconstrução  $\hat{f}$  para cada um destes conjuntos, teremos os subsídios necessários para apreender sob que condições cada um dos componentes contribuem para a qualidade ou acurácia da reconstrução do fenômeno de interesse.

A seguir ilustramos a aplicação dos processos de reconstrução para os diferentes conjuntos de dados.

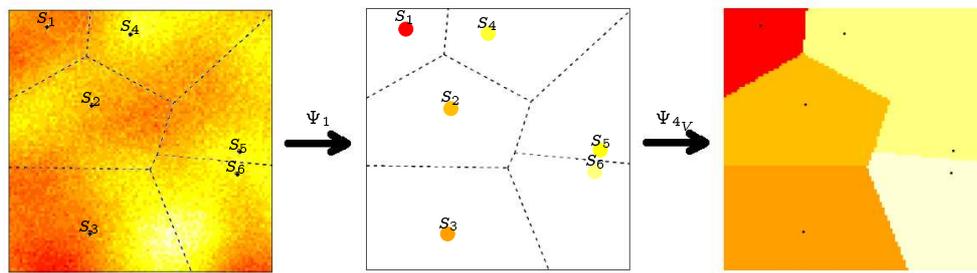
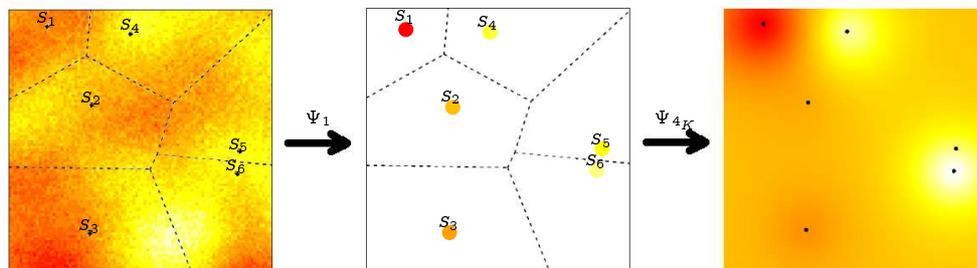
#### 3.3.8.1 Reconstrução a partir da amostragem individual

A reconstrução do fenômeno a partir dos dados das amostragens individuais dos sensores ainda não clusterizados,  $\hat{f}_{\Psi_1}$ , resultante do processo de reconstrução por Voronoi  $\Psi_{4V}$  ou do processo de reconstrução por Kriging  $\Psi_{4K}$ , viabiliza a avaliação do desempenho da rede quanto ao monitoramento e a qualidade da reconstrução no contexto das quatro primeiras camadas do nosso modelo genérico.

Ao desconsiderarmos a aplicação dos processos de clusterização e de agregação, e como consequência suas possíveis contribuições, estamos conduzindo a análise da reconstrução  $\hat{f}$  considerando os aspectos relacionados com: (i) a região monitorada, (ii) o fenômeno sob observação, (iii) as características percepção dos sensores e por fim (iv) a distribuição destes sensores.

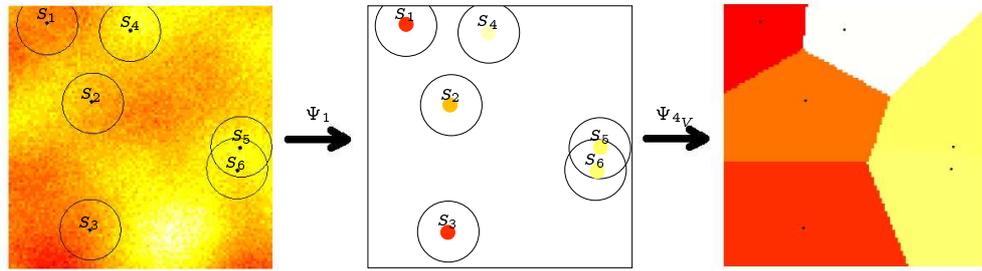
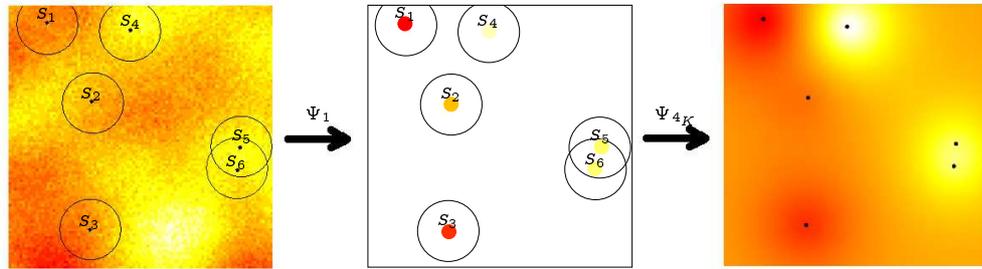
Considerando a *situação 1* e a *situação 2* modeladas neste trabalho, as figuras 3.21 e 3.22, respectivamente, ilustram a reconstrução  $\hat{f}_{\Psi_1}$  de uma amostra  $f$  do fenômeno sendo monitorado pela rede sensores, obtida pelo processo de reconstrução por Voronoi  $\Psi_{4V}$  e pelo processo de reconstrução por Kriging  $\Psi_{4K}$  a partir da amostragem individual dos sensores  $\Psi_1$ .

As figuras 3.21(a) e 3.21(b) ilustram, respectivamente, os processos de reconstrução por Voronoi e por Kriging realizados a partir dos dados de amostragem enviados à estação base por seis sensores *tipo 1*. Face as características de percepção deste tipo de sensores, modeladas na Seção 3.3.4, não ocorrem sobreposições entre as áreas de percepção dos sensores nem muito menos áreas da região não percebidas pela rede de sensores.

(a) Voronoi  $\Psi_{4V}$ (b) Kriging  $\Psi_{4K}$ Figura 3.21: Processo de reconstrução a partir da amostragem  $\Psi_1$  na *situação1*

Igualmente, nas figuras 3.22(a) e 3.22(b), ilustramos os processos de reconstrução por Voronoi e por Kriging, respectivamente, aplicados aos dados das amostragens individuais dos sensores agora modelados como *tipo2*. Em função das características de percepção deste tipo de sensores, apresentadas na Seção 3.3.4, percebemos que não mais ocorreu a cobertura total de percepção como ocorreu naturalmente na *situação1* (ver figuras 3.21(a) e 3.21(b)) por considerar as áreas de percepção dos sensores definidas com base no particionamento da região pelo diagrama de Voronoi. Ao compararmos visualmente a amostragem do sensor  $S_3$ , entre as figuras 3.21(a) e 3.22(a), percebemos as contribuições das diferentes características de percepção e, conseqüentemente, da falta de cobertura.

Além da falta de cobertura, na *situação2*, passa a existir a possibilidade de sobreposição entre as áreas de percepção dos sensores, como ocorre nas ilustrações da figura 3.22 entre os sensores  $S_5$  e  $S_6$ . Esta sobreposição já não ocorre na *situação1*, conforme podemos perceber nas ilustrações da figura 3.21.

(a) Voronoi  $\Psi_{4V}$ (b) Kriging  $\Psi_{4K}$ Figura 3.22: Processo de reconstrução a partir da amostragem  $\Psi_1$  na *situação2*

Embora tenhamos ilustrado a aplicação dos processos de reconstrução por Voronoi e por Kriging levando em conta apenas variações quanto ao aspecto relacionado às características de percepção dos sensores, em nossas simulações, com exceção da região monitorada e do número de sensores, realizamos experiências Monte Carlo nas quais consideramos todos os demais aspectos (ver Seção 3.5).

### 3.3.8.2 Reconstrução a partir da clusterização/agregação

O resultado  $\hat{f}_{\Psi_3}$  do processo de reconstrução  $\Psi_4$  realizado a partir dos dados recebidos da rede de sensores após terem ocorrido os processos de amostragem, de clusterização e de agregação, permite a avaliação do desempenho ou acurácia da rede de sensores no contexto global dos componentes que compõem no nosso modelo genérico.

Ao considerarmos as contribuições dos processos de clusterização e de agregação, ampliamos a análise da qualidade da reconstrução  $\hat{f}$  passando a avaliar todos os aspectos relacionados com: (i) a região sob monitoração, (ii) o fenômeno de interesse, (iii) as características de percepção dos sensores, (iv) as características de comunicação dos sensores, (v) a distribuição dos sensores, (vi) os protocolos de clusterização LEACH e SKATER e suas peculiaridades e por fim (vii) o emprego dos operadores de agregação.

Considerando a *situação1*, nas figuras 3.23(a) e 3.23(b) ilustramos a reconstrução  $\hat{f}_{\Psi_3}$ , de uma amostra  $f$  do fenômeno monitorado, obtida pelo processo de reconstrução por Voronoi  $\Psi_{4V}$  e pelo processo de reconstrução por Kriging  $\Psi_{4K}$ , respectivamente, a partir das agregações  $\Psi_{3L}$  realizadas por sensores *tipo1* membros dos *clusters*  $C_1$ ,  $C_2$  e  $C_3$  formados pelo protocolo LEACH (conferir a clusterização na figura 3.16).

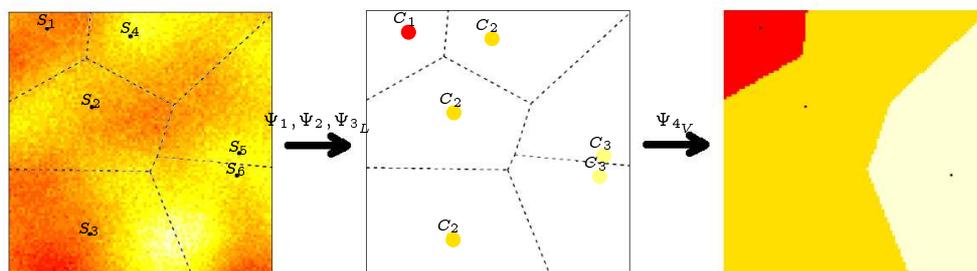
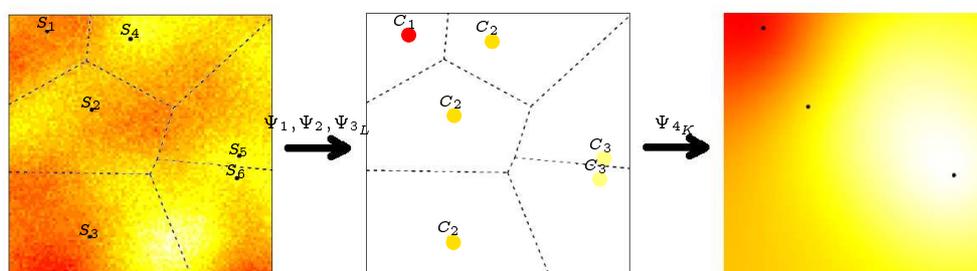
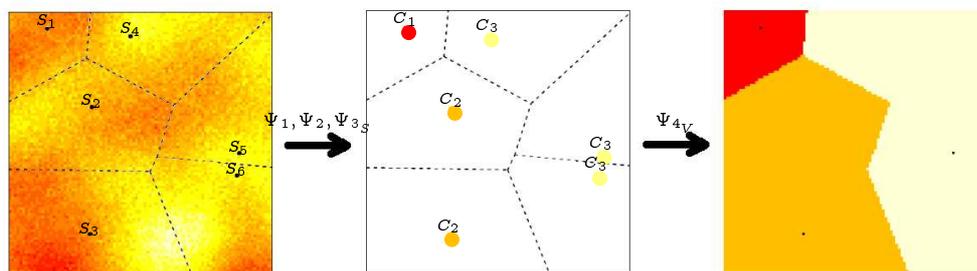
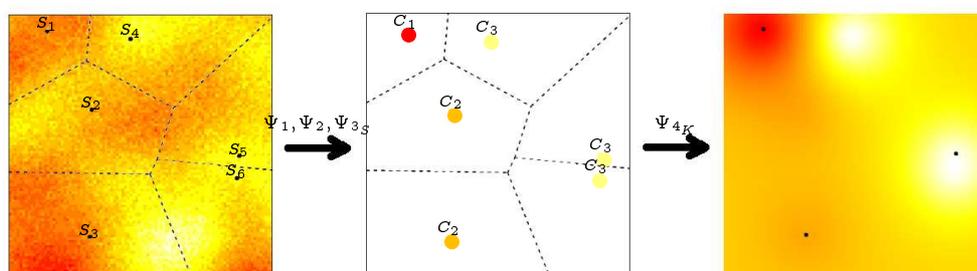
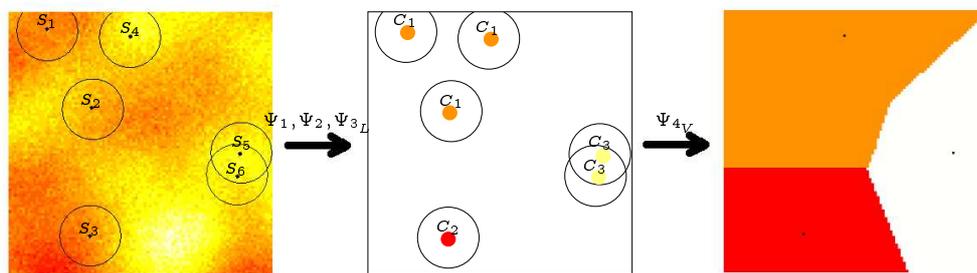
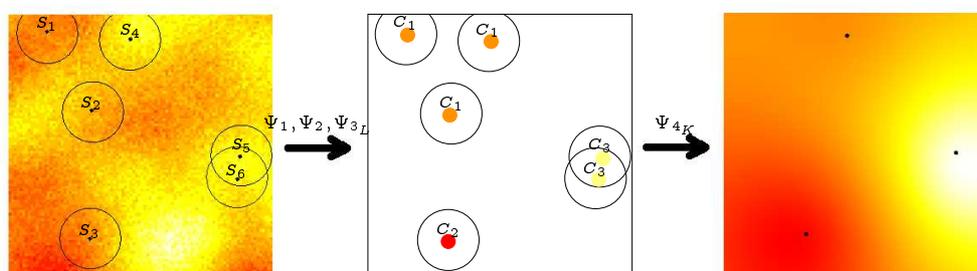
(a) Voronoi  $\Psi_{4V}$ (b) Kriging  $\Psi_{4K}$ 

Figura 3.23: Processo de reconstrução a partir da clusterização/agregação  $\Psi_{3L}$  na *situação1*

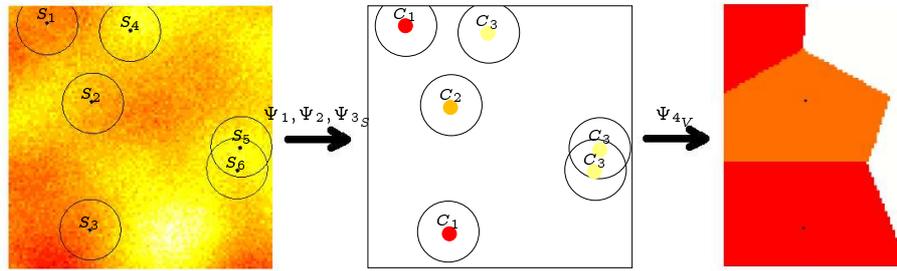
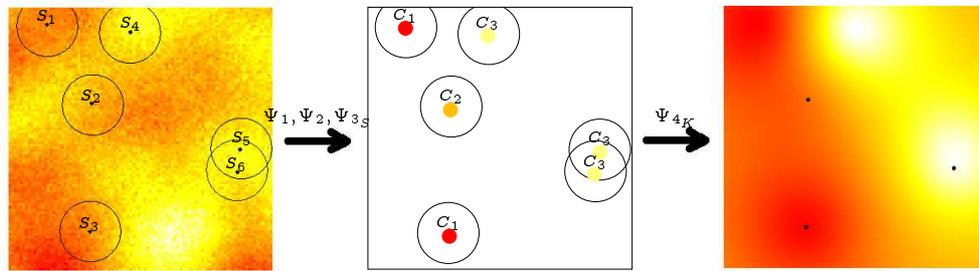
Da mesma forma, e ainda na *situação1*, as figuras 3.24(a) e 3.24(b) ilustram a reconstrução  $\hat{f}_{\Psi_3}$  obtida pelo processo de reconstrução por Voronoi  $\Psi_{4V}$  e pelo processo de reconstrução por Kriging  $\Psi_{4K}$  a partir das agregações  $\Psi_{3S}$  realizadas pelos sensores *tipo1* clusterizados pelo protocolo SKATER (chegar formação dos *clusters* na figura 3.17).

(a) Voronoi  $\Psi_{4V}$ (b) Kriging  $\Psi_{4K}$ Figura 3.24: Reconstrução a partir da clusterização/agregação  $\Psi_{3S}$  na *situação1*

Agora, considerando a *situação2*, ilustramos nas figuras 3.25(a) e 3.25(b) a reconstrução  $\hat{f}_{\Psi_3}$ , de uma amostra  $f$  do fenômeno monitorado, obtida pelo processo de reconstrução por Voronoi  $\Psi_{4V}$  e pelo processo de reconstrução por Kriging  $\Psi_{4K}$ , respectivamente, a partir das agregações  $\Psi_{3L}$  realizadas pelos sensores *tipo2* clusterizados pelo protocolo LEACH (ver nova formação dos clustes na figura 3.18).

(a) Voronoi  $\Psi_{4V}$ (b) Kriging  $\Psi_{4K}$ Figura 3.25: Reconstrução a partir da clusterização/agregação  $\Psi_{3L}$  na *situação2*

E por fim, através das figuras 3.26(a) e 3.26(b), ilustramos, para a *situação2*, a reconstrução  $\widehat{f}_{\Psi_3}$  obtida pelo processo de reconstrução por Voronoi  $\Psi_{4V}$  e pelo processo de reconstrução por Kriging  $\Psi_{4K}$  a partir das agregações  $\Psi_{3S}$  realizadas pelos sensores *tipo2* agrupados pelo protocolo SKATER (ver clusterização ilustrada na figura 3.19).

(a) Voronoi  $\Psi_{4V}$ (b) Kriging  $\Psi_{4K}$ Figura 3.26: Reconstrução a partir da clusterização/agregação  $\Psi_{3S}$  na *situação2*

### 3.4 Flexibilidade do Modelo

Muito embora na Seção 3.3 tenhamos definido cada uma das oito abstrações do nosso modelo genérico ao modelarmos a área e o fenômeno sob observação, os sensores e sua distribuição, o processo de amostragem, o processo de clusterização utilizando nossas adaptações dos protocolos LEACH e SKATER, o processo de agregação e finalmente o processo de reconstrução, postulamos e defendemos nesta seção que tal modelo não se encontra limitado a nossas definições. Tal como formulado, o modelo pode ter um ou mais de seus componentes ajustados ou mesmo substituídos de acordo com as necessidades do projeto de rede de sensores sendo implementado.

Analizamos a seguir a flexibilidade do nosso modelo traçando um paralelo entre suas abstrações e a técnica de agregação *In-Network* baseada em *clusters* denominada CAG (Yoon & Shahabi, 2007). Ao traçarmos este paralelo enquadrarmos a técnica CAG na estrutura de camadas proposta por nosso modelo genérico, facilitando assim as análises e intervenções quando se fizerem necessárias adições, supressões ou alterações de componentes do modelo. Escolhemos a técnica CAG pelo fato de ela apresentar características semelhantes aos protocolos LEACH e SKATER no tocante à correlação de dados, à topologia de rede e à precisão (ver Seção 2.3, página 7), bem como pelo fato de ser uma proposta recente na literatura.

#### 3.4.1 Região monitorada e fenômeno em observação

Em Yoon & Shahabi (2007) diversos estudos foram realizados considerando diferentes fenômenos e áreas sob monitoração. Eles consideraram tanto ambientes fechados (*indoor*) quanto abertos (*outdoor*).

Em alguns casos, foram montados experimentos em áreas reais com objetivos de medir dados reais de fenômenos como temperatura, luminosidade, umidade e pressão. Estas áreas foram: (i) área de

100m×100m no Parque de Exposição em Los Angeles (ambiente aberto), (ii) 4º andar do prédio *Tutor Hall* da University of Southern California (USC, ambiente fechado) e (iii) área de 100m×100m na região denominada *Great Duck Island* (ambiente aberto).

Em outros casos, foram realizadas simulações considerando dados espacialmente correlacionados gerados a partir de modelos estatísticos (sugeridos, segundo Yoon & Shahabi (2007), por Jindal & Psounis, 2004) e ecológicos (disponibilizados em Levis et al., 2003, segundo os mesmos autores) e registrados em matrizes de 62500 pixels (250 × 250). Estas matrizes representam os dados de fenômenos a serem medidos pelos sensores numa região de 250m<sup>2</sup> sob monitoração. A cor de cada pixel representa o valor da intensidade do fenômeno medido por um sensor localizado nas coordenadas do pixel.

### 3.4.2 Distribuição dos sensores

A depender dos objetivos, a distribuição dos sensores se deu sob as seguintes condições: processo regular, processo irregular e processo independente.

A distribuição dos sensores como um processo regular ocorreu nos experimentos realizados nas áreas: (i) Parque de Exposição de Los Angeles onde 100 sensores foram posicionados regularmente numa área de 100m<sup>2</sup> e (ii) 4º andar do prédio *Tutor Hall* da Universidade USC onde 40 sensores foram distribuídos regularmente em equidistância de 5m pelas salas e corredores.

O processo irregular se deu nos experimentos realizados na região *Great Duck Island* onde 35 sensores foram distribuídos irregularmente numa área de 100m×100m com o objetivo de medir a temperatura durante quatro dias a cada intervalo de quatro horas. O artigo não fornece informações suficientes de modo a especificar rigorosamente a forma em que os sensores foram distribuídos espacialmente, porém a figura 4(c) da referência, que corresponde a esta experiência, permite suspeitar que três processos atrativos seriam capazes de descrever essa localização.

O processo independente ou aleatório de distribuição dos sensores ocorreu nas simulações cujos dados não foram medidos por sensores reais mas sim gerados a partir dos modelos. Assumindo a região de 250m<sup>2</sup>, a distribuição espacial independente foi utilizada para diferentes densidades de sensores: 375 (que produziu uma média de 17 vizinhos por sensor, sendo considerada como densidade moderada), 550 (densa, com uma média observada de 26 vizinhos) e 200 (esparso, com uma média observada de 9 vizinhos por sensor).

### 3.4.3 Sensores

Nos experimentos, os dados foram medidos utilizando-se os sensores (*motest*) modelo *mica2*, fabricados pela empresa Crossbow Technology Inc (2008). Cada sensor está montado em uma placa *MTS 300*, e possui capacidade para medir luminosidade, temperatura, umidade e pressão.

O rádio de comunicação utilizado no *mica2* foi o *Chipcon CC1000* de 433MHz que, nos experimentos, atingiu taxas de recepção próximas a 100% em distâncias de até 25m, considerando configurações padrões de consumo de energia.

Foi utilizado o simulador *TOSSIM* de aplicações TinyOS para validar a eficiência do CAG quando operado tanto no modo *interativo* quanto no modo *streaming*.

### 3.4.4 Amostragem

Os dados de amostragem foram obtidos por dois tipos de experimentos: (i) dados de amostragem utilizando-se sensores do modelo *mica2* e (ii) dados gerados a partir de modelos estatísticos e ecológicos.

No primeiro tipo de experimento, a amostragem foi realizada considerando três situações: (i) distribuição regular dos sensores num ambiente *outdoor*, (ii) distribuição regular num ambiente *indoor* e (iii) distribuição irregular dos sensores num ambiente *outdoor*. Foram coletadas vinte amostras em intervalos de 200 milissegundos em cada sensor.

No segundo tipo de experimento, a amostragem foi realizada através de simulações. Considerando uma área de 250m<sup>2</sup>, foram gerados alguns conjuntos de dados espacialmente correlacionados. Para cada experimento, os sensores foram distribuídos aleatoriamente nessa área, e o valor de amostragem de cada sensor, com localização  $(x, y)$ , foi tomado como o valor do pixel  $(x, y)$  do conjunto de dados sendo utilizado.

### 3.4.5 Clusterização

O algoritmo utilizado pelo CAG computa respostas aproximadas para consultas dos usuários da rede de sensores. Dependendo dos requisitos da aplicação, o CAG pode trabalhar em um dos seus dois modos de operação: (i) modo *interativo* e (ii) modo *streaming*. Em ambos os modos, o algoritmo opera em duas fases: (i) fase de consulta e (ii) fase de resposta.

#### 3.4.5.1 Modo *interativo*

No modo *interativo*, o processo de clusterização é iniciado e concluído na fase de consulta. Esta fase inicia-se no instante em que o usuário dispara uma consulta especificando um atributo monitorado de interesse e uma taxa de erro  $\tau$  aceitável para a resposta esperada.

Disparada a consulta, a estação base faz um *broadcast* do pacote de consulta para todos os sensores da rede ao seu alcance. Ao receber o pacote de consulta, cada sensor decide se irá ingressar no *cluster* do remetente, caso ele verifique que seu valor de amostragem  $MR$  para o atributo está no intervalo de clusterização. Decidido pelo ingresso, o sensor encaminha o pacote, sem alterá-los, aos demais sensores em seu raio de comunicação. Caso o valor amostrado pelo sensor esteja fora do intervalo de clusterização, o sensor inicia um novo *cluster* se definindo como o *cluster head*, e envia o pacote de consulta aos demais sensores após alterá-lo com a seguinte atribuição  $CR = MR$ .

O intervalo de clusterização é definido como  $[CR - Range \times \tau, CR + Range \times \tau]$ , onde  $CR$  representa a valor de amostragem do *cluster head* e  $Range$  é a diferença entre os valores máximo e mínimo de todo o conjunto de observações.

A clusterização no modo *interativo* estará concluída para uma certa consulta quando a árvore de encaminhamento estiver completa, ou seja, quando cada um dos sensores da rede tiver recebido um pacote de consulta.

#### 3.4.5.2 Modo *streaming*

No modo *streaming*, os *clusters* são inicialmente formados na fase de consulta da mesma forma que ocorre no modo *interativo*. O objetivo do algoritmo CAG no modo *streaming* é gerar respostas periódicas a partir de uma única consulta do usuário. Como os dados sob observação se alteram com o tempo, ajustes periódicos nos *clusters* se tornam necessários de forma a garantir que os valores amostrados por todos os seus membros estejam consistentes em relação aos intervalos de clusterização.

### 3.4.6 Agregação

Formados os *clusters* na fase de consulta, inicia-se a fase de resposta. Todo o processo de agregação é realizado nesta fase.

Iniciada a fase de resposta, todos os sensores irão responder às consultas enviando suas respostas no sentido inverso ao da árvore de encaminhamento formada na fase anterior. As operações de agregação serão realizadas exclusivamente pelos *cluster heads* com base nos pacotes de resposta. Caso um sensor membro receba um pacote resposta, ele apenas irá reencaminhá-lo.

As operações de agregação de dados utilizadas pelo CAG são: (i) o *contador* do número de membros de cada *cluster*, (ii) a *soma*, (iii) a *média*, (iv) a *variância*, (v) o *desvio padrão*, (vi) o *máximo* e (vii) o *mínimo*.

#### 3.4.6.1 Modo *interativo*

Por apresentar o comportamento de apenas uma resposta da rede para uma consulta do usuário, fazendo assim uso apenas da correlação espacial dos dados, o CAG no modo *interativo* apenas garante respostas respeitando o erro aceitável  $\tau$  para as operações de agregação *máximo* e *mínimo*.

Ao agregar com o operador *mínimo*, o *cluster head* processa um pacote de resposta contendo como resultado o menor valor de todas as respostas por ele recebidas. Este pacote é então encaminhado no sentido inverso da árvore de encaminhamento na direção do usuário.

#### 3.4.6.2 Modo *streaming*

No modo *streaming*, a fase de resposta se prolonga por vários períodos para cada consulta do usuários. O tamanho de cada *cluster* é computado pelo *cluster head* ao receber, dos sensores membros, mensagens

do tipo *count increment* e *count decrement* enviadas durante a fase de formação e nos períodos de ajustes dos *clusters*.

O custo em estimar os tamanhos (peso) dos *cluster* passa a ser amortizado com o tempo possibilitando que esta informação esteja sempre disponível para os *cluster heads*. Desta forma, as operações de agregação *contador*, *soma*, *média*, *variância* e *desvio padrão* garantem respostas respeitando o erro aceitável  $\tau$  especificado pelo usuário.

### 3.4.7 Reconstrução

Embora no trabalho realizado com o CAG (Yoon & Shahabi, 2007) os autores não trataram do processo de reconstrução de fenômeno monitorado, eles avaliaram a eficiência e acurácia da técnica e chegaram a conclusão de que, no modo *streaming*, o erro absoluto da resposta da rede de sensores a uma consulta está sempre dentro do limite aceitável de erro desejado pelo usuário, independentemente da distribuição que caracteriza os dados.

## 3.5 Estudo Monte Carlo

Construído o nosso modelo genérico, na Seção 3.3, composto pelas abstrações que modelam cada um dos elementos (enumerados à página 16) que descrevem o fenômeno de interesse, conduzimos nossas simulações por meio de experiências Monte Carlo.

Considerando que nosso modelo, na formulação apresentada neste trabalho, abrange diversos aspectos relacionados com a região e o fenômeno sob monitoração, com as operações de amostragem, clusterização e agregação realizadas pela rede de sensores e por fim com os processos de reconstrução do fenômeno, estruturamos um estudo Monte Carlo utilizando cada uma dessas variáveis como um fator.

Definida uma região de floresta com área plana de  $100\text{m} \times 100\text{m}$  e o número  $n = 100$  de sensores, para cada uma das situações modeladas (*situação1* e *situação2*, definidas nas Seções 3.3.4.1 e 3.3.4.2 respectivamente), simulamos a reconstrução do fenômeno a partir dos dados resultantes das operações realizadas pela rede de  $n$  sensores, replicando 100 (cem) vezes cada uma das seguintes situações

- Fenômeno iluminação descrito pelo processo estocástico do tipo campo aleatório gaussiano nas escalas  $s \in \{5, 10, 15, 20\}$
- Distribuição espacial dos  $n$  sensores através do processo estocástico do tipo processo pontual  $C(n, a)$  com parâmetro  $a \in \{-\infty, -30, -15, 0, 5, 15, 30\}$  (ver modelagem na Seção 3.3.3, página 18).

Esse número de replicações, isto é, 100 foi considerado suficiente para ter boas estimativas.

As realizações dessas experiências Monte Carlo têm como objetivo a extração de informações do nosso modelo para avaliarmos o erro ou a qualidade da reconstrução do fenômeno sendo monitorado ao aplicarmos os dois processos de reconstrução, Voronoi e Kriging, utilizados neste trabalho (ver Seção 3.3.8).

Na Seção 4.5 do capítulo 4 apresentaremos alguns resultados e avaliações do erro de reconstrução para a *situação1*.

Na Seção 4.6 do mesmo capítulo, serão disponibilizados alguns resultados e avaliações referentes as simulações para a *situação2*.

E por fim, no capítulo 4 apresentaremos na Seção 4.7 algumas avaliações e resultados obtidos ao confrontarmos a *situação1* com a *situação2*.

## 3.6 Detalhes de implementação e execução

Formulado nosso modelo genérico e definida a estrutura das simulações, detalhamos nesta seção as plataformas computacionais utilizadas e as considerações e decisões de implementação e de execução adotadas neste trabalho.

### 3.6.1 Plataformas computacionais

Neste trabalho, para a implementação e execução das simulações, adotamos a utilização integrada do seguinte conjunto de ferramentas e plataformas computacionais:

- plataforma R (R Development Core Team, 2006), versão 2.4.0

- plataforma Eclipse SDK (Eclipse Project, 2006), versão 3.1.2
- IDE C/C++ Development Tools (Eclipse CDT Project, 2006), versão 3.0.2
- compilador GCC (GNU Project, 2007), versão 4.1.2
- *cluster* com 32 nós (ver <http://cluster.lccv.ufal.br>)

Todas elas executam Linux, as quatro primeiras na distribuição Debian e a última na Fedora.

### 3.6.2 Execução das simulações

Na figura 3.27 ilustramos de que forma utilizamos e integramos essas plataformas e ferramentas para a execução das simulações propostas. A caixa em azul com a letra *R* representa a plataforma *R* instalada no nó *master* do *cluster*. Abaixo desta caixa, as caixas em vermelho representam as plataformas *R* instaladas nos demais nós do *cluster* (31 nós utilizados nas simulações). A caixa em azul com as letras *GCC* representa o compilador GCC do nó *master* do *cluster* e, analogamente, as caixas em vermelho logo abaixo representam os compiladores GCC dos demais nós do *cluster* participantes das simulações. Mais acima, a caixa verde representa o sistema de arquivo compartilhado por todos os nós do *cluster* (*NFS*, *Network File System*). Todos os dados gerados pelos nós durante simulações são gravados numa área desse sistema de arquivo.

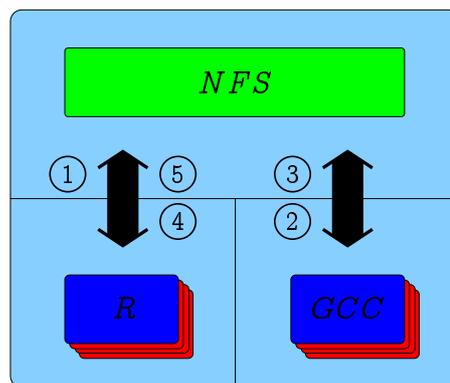


Figura 3.27: Plataformas e Ferramentas - Integração

Para auxiliar o detalhamento da seqüência de execução das simulações, incluímos na figura 3.27 os círculos numerados. Seguindo a numeração dos círculos, apresentamos a seqüência de execução das simulações:

- 1 - Geração, pela plataforma *R* do nó *master*, dos dados de distribuição dos sensores nos processos pontuais  $a = \{-\infty, -30, -15, 0, 5, 15, 30\}$  e dos dados do fenômeno  $f$  nas escalas  $s = \{5, 10, 15, 20\}$  (Dados gerados: 100 arquivos de dados para cada processo pontual  $a$  e para cada escala  $s$ );
- 2 - Distribuição do processamento das simulações de amostragem, clusterização e agregação, segundo o estudo Monte Carlo, para os compiladores GCC dos 31 nós do *cluster*;
- 3 - Gravação dos resultados das simulações realizadas, em paralelo, pelos compiladores dos nós do *cluster* (Dados gerados: 2800 arquivos contendo dados da amostragem individual dos sensores  $\Psi_1$ , dados de agregação a partir da clusterização por LEACH  $\Psi_{3_L}$  e dados de agregação a partir da clusterização por SKATER  $\Psi_{3_S}$ , sendo 100 arquivos para cada uma das 28 combinações entre os processos pontuais  $a$  e as escalas  $s$ );
- 4 - Distribuição do processamento das simulações de reconstrução a partir de  $\Psi_1$ , de  $\Psi_{3_L}$  e de  $\Psi_{3_S}$  para as plataformas *R* dos 31 nós do *cluster*;
- 5 - Gravação dos resultados das execuções, em paralelo, realizadas pelas plataformas *R* dos nós do *cluster* (Dados gerados: 5600 arquivos, sendo 2800 para o processo de reconstrução por Voronoi  $\Psi_{4_V}$  e 2800 para o processo de reconstrução por Kriging  $\Psi_{4_K}$ , contendo dados de reconstrução do fenômeno  $f$  a partir dos conjuntos  $\Psi_1$ ,  $\Psi_{3_L}$  e  $\Psi_{3_S}$ ).

Da sequência de execução acima, apenas a primeira etapa (item 1) é executada uma única vez. Os dados nela gerados são utilizados por todas as situações definidas neste trabalho (*situação1*, *situação2* e *situação3* com raio de comunicação  $r_c = 15\text{m}$ ). As demais etapas (itens 2,3,4,5), são executadas separadamente para cada situação.

Na sequência de execução realizada para a *situação2* com raio de comunicação  $r_c = 15\text{m}$ , apenas são consideradas as simulações contendo o processo pontual regular  $a = -\infty$  com quaisquer das escalas  $s = \{5, 10, 15, 20\}$  (ver detalhes na Seção 3.6.4.1, página 44).

### 3.6.3 Considerações de implementação

Nesta seção levantamos considerações e decisões que foram tomadas quando da implementação das nossas simulações.

#### 3.6.3.1 Geração dos dados do fenômeno $f$

Seguindo o estudo de Reis et al. (2007), para descrevermos o fenômeno iluminação  $f$  sendo observado pela rede de sensores sem fios, utilizamos neste trabalho um processo estocástico do tipo campo aleatório gaussiano, estacionário e isotrópico, com média zero (ver Seção 2.4.1, página 10).

Para a geração dos dados do fenômeno de iluminação  $f$ , modelado na Seção 3.3.2 (página 17), utilizamos o pacote *RandomFields* (Schlather, n.d.) disponível para a plataforma R.

Os dados gerados a partir do modelo do fenômeno  $f$  são registrados em arquivos na forma de uma matriz de 10000 pixels ( $100 \times 100$ ). Nesta matriz, os valores dos pixels representam a intensidade da iluminação incidente na área monitorada e a correlação entre estes valores definida pelo parâmetro escala  $s$  do modelo define a granularidade do fenômeno.

#### 3.6.3.2 Geração dos dados de distribuição dos sensores

Considerando os processos pontuais  $a = \{-\infty, -30, -15, 0, 5, 15, 30\}$  definidos neste trabalho, utilizamos o pacote *spatstat* (Baddeley & Turner, 2005) da plataforma R para a geração dos dados de distribuição dos 100 sensores sobre a região de floresta monitorada (ver modelagens nas Seções 3.3.1 e 3.3.3, páginas 17 e 18 respectivamente).

#### 3.6.3.3 Células de Voronoi

Em cada arquivo de dados de distribuição dos sensores, registramos, também, as informações relativas às células do Diagrama de Voronoi computadas a partir das posições dos sensores. Para isso, utilizamos o pacote *deldir* (Turner, 2007) da plataforma R. As células de Voronoi são utilizadas pelo processo de amostragem da *situação1* e pelo processo de reconstrução por Voronoi empregado em todas as situações (*situação1*, *situação2* e *situação3* com  $r_c = 15\text{m}$ ).

#### 3.6.3.4 Área de percepção

Na *situação1* modelamos a área de percepção  $A_i$  de um sensor  $S_i$  como a área de célula de Voronoi a ele associada (ver equação 3.2 na página 22).

Na *situação2* a área de percepção  $A_i$  de um sensor  $S_i$  é caracterizada pela função de resposta radial desse sensor definida pela equação 3.3 (página 22).

O diagrama de Voronoi definido pelos pontos de localização dos sensores particiona a região monitorada, de  $10000\text{m}^2$ , em tantas células quanto o número de sensores. Assim, na *situação1*, assumimos que a área média de percepção dos 100 sensores é de  $100\text{m}^2$ .

Equalizando com a *situação1*, definimos o raio de percepção dos sensores da *situação2* para  $r_p = \sqrt{100/\pi} \approx 5.6418$  metros. Com este raio, a área circular de percepção dos sensores da *situação2* é, também, de  $100\text{m}^2$ .

#### 3.6.3.5 Processos atrativos e região alvo

Em nossas simulações, a distribuição dos sensores é definida através do processo pontual  $C(n, a)$  definido neste trabalho pela equação 3.1 na página 19.

Na distribuição de sensores pelos processos atrativos ( $a > 1$ ), o parâmetro  $a$  define a concentração de sensores numa área alvo da região de floresta monitorada. A área total da região de floresta

sendo monitorada é de  $100\text{ m} \times 100\text{ m}$ . Modelamos a área alvo (área de concentração) com as dimensões  $25\text{ m} \times 25\text{ m}$  e localizada no canto inferior esquerdo em relação a região da floresta.

Na figura 3.28 a região em azul representa a área alvo considerada em nossas simulações para os processos pontuais atrativos  $\alpha = \{5, 15, 30\}$ .

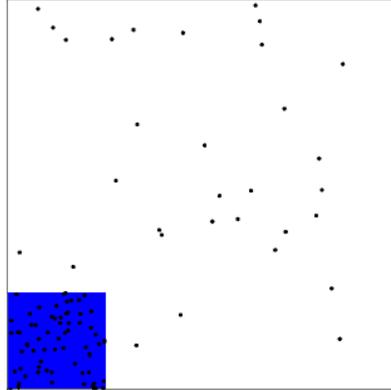


Figura 3.28: Processo Atrativo e região alvo

### 3.6.3.6 Raio de comunicação $r_c$

Tipicamente, a depender do raio de comunicação, a ocorrência de isolamentos de sensores é mais provável nas áreas com baixa densidade de distribuição espacial de sensores. Em nossas simulações, considerando as dimensões fixas da região monitorada e o número de sensores, quanto maior a atratividade do processo pontual maior a exposição dos sensores fora da região de concentração (ver Seção 3.6.3.5) à condição de isolamento.

Definimos em  $r_c = 36\text{ m}$  o valor do raio de comunicação padrão utilizado nas simulações da *situação 2*. Este valor foi definido após avaliarmos todos os dados de distribuição espacial dos sensores gerados pela plataforma R para todos os processos pontuais e verificarmos ser este raio suficiente para evitar o isolamento de quaisquer dos sensores durante o processo de clusterização.

### 3.6.3.7 Número de *clusters*

Considerando o estudo e os resultados obtidos por Reis et al. (2007), adotamos também como seis o número de *clusters* para os processos de clusterização  $\Psi_{3_L}$  e  $\Psi_{3_S}$ .

### 3.6.3.8 LEACH e a formação dos *clusters*

Originalmente, conforme expõem seus autores em Heinzelman et al. (2000), o algoritmo do protocolo LEACH, definido o número  $n$  de iterações ou *rounds* desejados, reconstrói  $n$  vezes os *clusters* considerando o balanceamento de energia entre os sensores.

Embora reconheçamos a importância da preservação de energia para o ciclo de vida das redes de sensores sem fios, e cientes da contribuição do trabalho de Heinzelman et al. (2000), neste trabalho para cada simulação exploramos as características de clusterização do LEACH considerando apenas uma iteração ou *round*. Assim sendo, na nossa implementação deste protocolo (realizada na linguagem C), só levamos em conta os aspectos relevantes para o nosso estudo.

### 3.6.3.9 LEACH e a escolha dos *clusters heads*

No LEACH a escolha dos *clusters heads* (CH) define a formação dos *clusters* e, como consequência, os resultados dos processos de reconstrução do fenômeno  $f$ . Escolhidos os CH, os *clusters* são formados agrupando os sensores restantes ao CH mais próximo. Desta forma, o LEACH constrói os *clusters* com base na relação espacial entre os sensores.

Considerando os impactos da escolha dos CHs, para cada simulação iteramos o LEACH dez vezes escolhendo a formação dos *clusters* com menores diferenças entre os valores de agregação e os valores de amostragem individual dos sensores. Além disto, na escolha dos *clusters heads*, é considerada a distância mínima de  $r_c = 30\text{ m}$  entre os CHs.

### 3.6.3.10 SKATER e a formação dos *clusters*

No artigo Assunção et al. (2006), os autores descrevem os algoritmos utilizados pelo SKATER para construir e particionar a árvore de mínimo custo formando, desta forma, os *clusters*. Os autores também apresentam uma heurística para melhorar o desempenho (tempo de execução) do particionamento da árvore. Neste trabalho, desconsiderando a questão do desempenho (heurística), implementamos o SKATER na linguagem C com base nos algoritmos propostos.

### 3.6.3.11 Estação base

Neste trabalho não consideramos questões relacionadas às características ou à localização da estação base receptora dos dados processados pela rede de sensores.

Consideramos que os dados resultantes das operações de amostragem, clusterização e agregação realizadas pelos sensores são enviados pela rede e recebidos pela estação base de forma íntegra para posterior processamento.

### 3.6.3.12 Reconstrução por Voronoi

Os dados de iluminação  $f$  percebidos, processados e enviados pela rede de sensores para a estação base, em conjunto com as informações de localização dos sensores, são disponibilizados aos usuários da rede para posterior processamento.

Da mesma forma que registramos os dados gerados do fenômeno  $f$  em cada simulação, os dados de reconstrução  $\hat{f}$  são também registrados numa matriz de 10000 pixels.

A partir das informações de localização de cada sensor  $S_i$ , o processo de reconstrução por Voronoi  $\Psi_{4V}$  define o diagrama de Voronoi utilizando o pacote *deldir* (Turner, 2007) da plataforma R, e associa cada pixel da matriz  $\hat{f}$  a uma das células do diagrama. Para cada sensor  $S_i$ , o processo de reconstrução atribui o valor do sensor  $S_i$ , processado e enviado pela rede, a todos os pixels de matriz  $\hat{f}$  que pertencem a célula de Voronoi associada ao sensor  $S_i$ .

Ao final de cada simulação, os dados da matriz de reconstrução  $\hat{f}$  são gravados para arquivo.

### 3.6.3.13 Modelo do Kriging adotado

Em nossas simulações, utilizamos o pacote *geoR* (Engelbrecht & Herz, 2001) e o pacote *sp* (Pebesma & Bivand, 2005) da plataforma R para a reconstrução de  $f$  pelo processo de reconstrução Kriging  $\Psi_{4K}$ .

Nas simulações, a entrada para o processo por Kriging é o mesmo conjunto de dados de processamento e de localização dos sensores utilizado como entrada para o processo de reconstrução por Voronoi.

Dentre os vários modelos de Kriging disponíveis na plataforma R, utilizamos o *kriging simple*. Nas simulações, o Kriging estima a superfície (neste caso  $\hat{f}$ ) utilizando os parâmetros calculados pelo método *likfit* disponível no pacote *geoR*. Passamos como argumentos para esse método, o modelo *mattern* da função de correlação e o parâmetro de suavização *kappa* com valor 1.5. O impacto destas escolhas na qualidade da reconstrução é objeto de outro estudo em andamento atualmente.

## 3.6.4 Ajustes de implementações

Nesta seção apresentamos alguns ajustes de implementação necessários para podermos confrontar os resultados das simulações obtidos entre a *situação1* e a *situação2*.

### 3.6.4.1 Comparando a *situação1* e *situação2* quanto à reconstrução a partir do SKATER

Para compararmos a *situação1* e a *situação2* quanto à qualidade de reconstrução a partir de  $\Psi_{3S}$  (SKATER), algumas condições foram estabelecidas e, quando necessário, alguns ajustes em nossas simulações foram realizados de forma a garantir um equilíbrio entre às situações quanto às características de percepção e de comunicação.

Na *situação1* a área de percepção de um sensor é definida como a célula de Voronoi associada a esse sensor. Considerando que em nossas simulações a rede de sensores é composta por 100 sensores e monitora uma área de 100 m × 100 m, o particionamento dessa área pelo diagrama de Voronoi, definido com base nas posições dos sensores distribuídos por quaisquer dos processos pontuais  $a = \{-\infty, -30, -15, 0, 5, 15, 30\}$ , confere, em média, uma área de 100 m<sup>2</sup> para cada célula. Desta forma, na *situação1*, assumimos que a área média de percepção dos sensores é de 100 m<sup>2</sup>.

Para a *situação2*, o raio de percepção dos sensores definido e utilizado por padrão em todas as simulações foi  $r_p = \sqrt{100/\pi} \approx 5.6418$  metros. Com este raio, cada sensor *tipo2* da *situação2* apresenta uma área radial de percepção, também, de  $100 \text{ m}^2$ .

Considerando a distribuição dos sensores pelo processo pontual regular  $a = -\infty$ , podemos considerar que as condições de percepção entre os sensores *tipo1* da *situação1* e os sensores *tipo2* da *situação2* estão equilibradas. Embora nesta condição haja o equilíbrio de percepção entre os diferentes tipos de sensores, comparando a área azul da figura 3.29(a), percebida pela rede de sensores na *situação1*, com a percepção da mesma área pela rede de sensores na *situação2*, notamos na figura 3.29(b) que na *situação2* há presença de regiões, em branco, não percebidas pelos sensores.

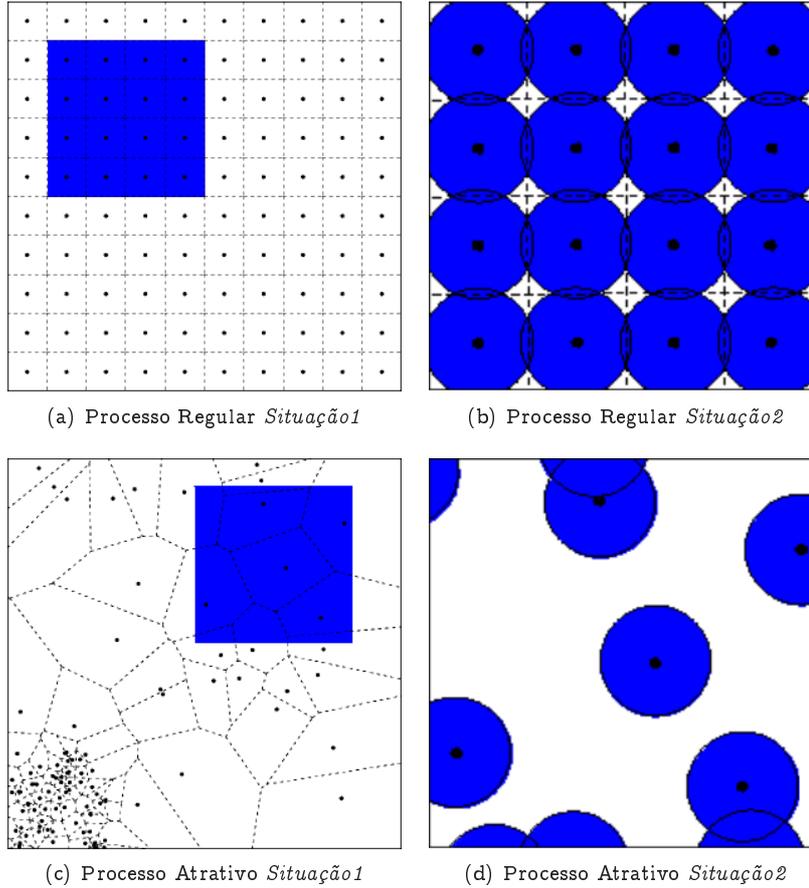


Figura 3.29: Áreas de Percepção na *Situação1* na e *Situação2*

Fazendo a mesma comparação entre as figuras 3.29(c) e 3.29(d) percebemos os impactos causados pela atratividade ao processo de amostragem  $\Psi_1$  da *situação2*. Quanto maior a atratividade da distribuição dos sensores, maior a falta de cobertura de percepção da rede de sensores.

Uma vez que as características de comunicação afetam as operações de clusterização e agregação realizadas pela rede de sensores, para podermos comparar o desempenho quanto à qualidade da reconstrução por Voronoi e por Kriging a partir da agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3_S}$ ), foi necessário ajustar nossas simulações para equilibrar essas características entre a *situação1* e a *situação2*.

O equilíbrio das características de comunicação entre a *situação1* e a *situação2* foi definido considerando as seguintes condições: (i) distribuição regular dos sensores e (ii) equiparação, entre as situações, do número máximo de vizinhos por sensor.

Na *situação1*, considerando que dois sensores são vizinhos sempre que suas células de Voronoi compartilham de pelo menos um vértice, cada sensor distribuído regularmente terá no máximo oito vizinhos.

Na *situação2* dois sensores são vizinhos sempre que um está no raio de comunicação  $r_c$  do outro. Nesta situação, uma vez que o raio de comunicação padrão  $r_c = 36 \text{ m}$  utilizado em nossas simulações confere o número máximo de 36 (trinta e seis) vizinhos por sensor, para igualarmos as características de comunicação entre a *situação2* e a *situação1* ajustamos nossas simulações configurando o valor do raio

de comunicação dos sensores *tipo2* para  $r_c = 15$  m. Com esta nova configuração, garantimos em oito o número máximo de vizinhos por sensor para ambas as situações, definindo assim o equilíbrio quanto às características de comunicação.

Na figura 3.30 ilustramos as áreas de comunicação para a *situação1* (área quadrada) e para a *situação2* (área radial). Podemos perceber que, em ambas as situações, o sensor em azul tem oito sensores vizinhos, c.f, aqueles dentro da área de comunicação.

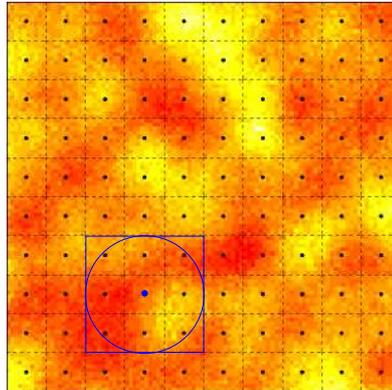


Figura 3.30: Áreas de Comunicação na *Situação1* na e *Situação2* com  $r_c = 15$  m

Desta forma, considerando as condições (distribuição regular dos sensores) e os ajustes de implementação (redução do raio de comunicação) apresentados, poderemos ao final deste trabalho avaliar os resultados da reconstrução por Voronoi e por Kriging aplicados a partir  $\Psi_{3s}$  confrontando a *situação1* com a *situação2*.

Este capítulo apresentou a metodologia que propomos para avaliar o desempenho de operação de redes de sensores sem fios. No próximo capítulo mostramos os resultados obtidos pela aplicação desta metodologia a um conjunto representativo de situações.

# Capítulo 4

## Resultados

Neste trabalho, foram medidos e avaliados os erros inerentes a dois processos de reconstrução do fenômeno do interesse: (i) a reconstrução por Voronoi  $\Psi_{4V}$  e (ii) a reconstrução por Kriging  $\Psi_{4K}$  (ver Seção 3.3.8, página 31).

Os processos de reconstrução foram aplicados a três conjuntos de dados: (i) amostragens individuais dos sensores ainda não clusterizados ( $\Psi_1$ ), (ii) agregação dos dados amostrados por sensores clusterizados pela técnica LEACH ( $\Psi_{3L}$ ) e (iii) agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3S}$ ). Nas Seções 3.3.5 e 3.3.6 foram formalizadas  $\Psi_1$  e  $\Psi_3$ , respectivamente.

Neste capítulo, apresentamos e avaliamos os resultados obtidos.

### 4.1 Execução das Simulações

Os resultados foram obtidos a partir das informações extraídas do nosso modelo genérico através das simulações conduzidas de acordo com o estudo Monte Carlo definido na Seção 3.5 (página 40). As simulações foram realizadas utilizando-se 32 nós de um *cluster*, cada nó representando um processador Intel Core 2 Duo 1.82 Ghz e 1 GB de memória RAM. (ver <http://cluster.lccv.ufal.br>).

Considerando as 100 replicações das simulações para cada combinação dos processos pontuais  $a = \{-\infty, -30, -15, 0, 5, 15, 30\}$  com as escalas  $s = \{5, 10, 15, 20\}$ , o tempo médio total de execução das 2800 simulações, para a *situação1* e para a *situação2* (apresentadas na Seção 3.3.4), foi de três horas.

### 4.2 Descrições das Avaliações das Estimções do Erro

Nesta seção descrevemos de que forma foram avaliados e comparados os erros introduzidos pelos processos de reconstrução, Voronoi  $\Psi_{4V}$  e Kriging  $\Psi_{4K}$ , para  $\Psi_1$  (amostragem individual dos sensores), para  $\Psi_{3L}$  (agregação da clusterização pela técnica LEACH) e para  $\Psi_{3S}$  (agregação da clusterização pela técnica SKATER) considerando a *situação1*, considerando a *situação2* e posteriormente considerando ambas as situações. Esses erros são avaliados pela média ( $\hat{\mu}$ ) e a variância ( $\hat{\sigma}^2$ ) dos dados obtidos pelas simulações.

Na tabela 4.1 estão descritas todas as comparações realizadas considerando apenas a *situação1*. Para cada um dos processos de reconstrução são comparados os erros para  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$  (descritivos  $Id = \{01, 02, 03, 04\}$ ). São também comparados os erros entre os dois processo de reconstrução para  $\Psi_1$ , para  $\Psi_{3L}$  e para  $\Psi_{3S}$  separadamente (demais descritivos, isto é,  $Id = \{05, 06, 07\}$ ).

Tabela 4.1: Descritivos das Avaliações do erro para a *situação1*

Id	Estimador	Processos de Reconstrução	Erro
01	$\hat{\mu}$	Voronoi	$\Psi_1, \Psi_{3L}$ e $\Psi_{3S}$
02	$\hat{\sigma}^2$	Voronoi	$\Psi_1, \Psi_{3L}$ e $\Psi_{3S}$
03	$\hat{\mu}$	Kriging	$\Psi_1, \Psi_{3L}$ e $\Psi_{3S}$
04	$\hat{\sigma}^2$	Kriging	$\Psi_1, \Psi_{3L}$ e $\Psi_{3S}$
05	$\hat{\mu}$	Voronoi e Kriging	$\Psi_1$
06	$\hat{\mu}$	Voronoi e Kriging	$\Psi_{3L}$
07	$\hat{\mu}$	Voronoi e Kriging	$\Psi_{3S}$

A tabela 4.2 tráz para a *situação2* as mesmas comparações da tabela 4.1 acrescentando mais três descritivos ( $Id = \{6, 8, 10\}$ ) e uma coluna com informações relativas aos processos pontuais. Aos compararmos os erros de reconstrução para o  $\Psi_{3_S}$ , confrontando duas configurações de raio de comunicação,  $r_c = 36$  m e  $r_c = 15$  m, com sensores regularmente distribuídos, evidenciamos a contribuição do raio de comunicação para a qualidade da reconstrução nas técnicas de clusterização que consideram a correlação espacial dos dados.

Tabela 4.2: Descritivos das Avaliações do erro para a *situação2*

Id	Estimador	Proc. Pontuais	Proc. de Reconstrução	Erro
01	$\hat{\mu}$	todos	Voronoi	$\Psi_1, \Psi_{3_L}$ e $\Psi_{3_S}$
02	$\hat{\sigma}^2$	todos	Voronoi	$\Psi_1, \Psi_{3_L}$ e $\Psi_{3_S}$
03	$\hat{\mu}$	todos	Kriging	$\Psi_1, \Psi_{3_L}$ e $\Psi_{3_S}$
04	$\hat{\sigma}^2$	todos	Kriging	$\Psi_1, \Psi_{3_L}$ e $\Psi_{3_S}$
05	$\hat{\mu}$	todos	Voronoi e Kriging	$\Psi_1$
06	$\hat{\sigma}^2$	todos	Voronoi e Kriging	$\Psi_1$
07	$\hat{\mu}$	todos	Voronoi e Kriging	$\Psi_{3_L}$
08	$\hat{\sigma}^2$	todos	Voronoi e Kriging	$\Psi_{3_L}$
09	$\hat{\mu}$	todos	Voronoi e Kriging	$\Psi_{3_S}$
10	$\hat{\mu}$	regular	Voronoi e Kriging	$\Psi_{3_S}, r_c = 36$ m e $r_c = 15$ m

Apresentamos na tabela 4.3 as descrições das comparações realizadas entre a *situação1* e a *situação2*.

As comparações da tabela 4.3 de  $Id = \{01, 02\}$  tratam especialmente dos erros de reconstrução da amostragem individual dos sensores  $\Psi_1$  confrontando-se as duas situações. Avaliar estes erros desconsiderando os processos de clusterização e de agregação evidencia as contribuições da falta de cobertura de monitoramento, da distribuição dos sensores e da granularidade do fenômeno sob observação exclusivamente quanto ao processo de amostragem.

Ao definirmos no descritivo de  $Id = \{03\}$  comparações entre o erro de reconstrução para  $\Psi_{3_S}$  na *situação1* e o erro de reconstrução para  $\Psi_{3_S}$  na *situação2* com  $r_c = 15$  m, considerando em ambos os casos a distribuição regular dos sensores, evidenciamos as influências da falta de cobertura de percepção sobre as operações de amostragem, clusterização e agregação realizadas pela rede de sensores que irão definir o resultado final do processo de reconstrução do fenômeno.

Traçar um paralelo dos erros de reconstrução para  $\Psi_{3_S}$  entre as duas situações só foi possível ao ajustarmos as simulações de forma a garantir um equilíbrio entre a *situação1* e *situação2* quanto às características de percepção e de comunicação (ver Seção 3.6.4.1). Discutimos esse ajuste a seguir.

Considerar os 100 sensores distribuídos regularmente na área de  $100\text{ m} \times 100\text{ m}$ , foi o primeiro ajuste para equilibrarmos as situações quanto às características de percepção e comunicação.

Na *situação1*, a área de percepção de um sensor foi definida como a área da célula de Voronoi a ele associada, enquanto que na *situação2* a área de percepção foi definida como a área circular de raio  $r_p$  definida em volta do sensor (ver figuras 3.11).

Ao simularmos a *situação1* com a distribuição regular dos sensores garantimos que a célula de Voronoi ou área de percepção de cada sensor teve uma área de exatamente  $100\text{ m}^2$ . Na *situação2*, em todas as simulações, independentemente do tipo de distribuição dos sensores, foi adotado um raio de  $r_p = \sqrt{100/\pi} \approx 5.6418$  metros como o raio de percepção dos sensores, conferindo assim para cada sensor um região circular de percepção também com área de  $100\text{ m}^2$ . Nestas configurações, as situações ficaram equilibradas quanto à área de percepção e assim em mesmas condições de amostragem.

Equilibradas quanto às características de percepção, foi necessário adotarmos um último ajuste para que as situações entressem em equilíbrio quanto às características de comunicação.

Na técnica SKATER a qualidade da construção dos *clusters* está diretamente relacionada com o número de sensores adjacentes (vizinhos) por sensor. Na *situação1*, definimos que dois sensores são adjacentes sempre que suas células de Voronoi compartilhem de um mesmo vértice. Já na *situação2*, dois sensores são adjacentes sempre que um está no raio de comunicação  $r_c$  do outro.

Considerando os 100 sensores distribuídos regularmente na área de  $100\text{ m} \times 100\text{ m}$ , e definindo para a *situação2* o raio de comunicação como sendo  $r_c = 15$  m, igualamos em 8 o número máximo de adjacentes dos sensores nas duas situações, podendo assim compará-las uma vez que passaram a estar também equilibradas quanto às características de comunicação.

Tabela 4.3: Descritivos das Avaliações do erro entre a *situação1* e a *situação2*

Id	Estimador	Proc. Pontuais	Proc. de Reconstrução	Erro
01	$\hat{\mu}$	todos	Voronoi e Kriging	$\Psi_1$ ( <i>situação1</i> ) e $\Psi_1$ ( <i>situação2</i> )
02	$\hat{\sigma}^2$	todos	Voronoi e Kriging	$\Psi_1$ ( <i>situação1</i> ) e $\Psi_1$ ( <i>situação2</i> )
03	$\hat{\mu}$	regular	Voronoi e Kriging	$\Psi_{3_S}$ ( <i>sit.1</i> ) e $\Psi_{3_S}$ ( <i>sit.2</i> ) $r_c = 15$ m

### 4.3 Medidas de Avaliação do Erro

Com o objetivo de avaliar o desempenho quanto a acurácia dos processos de reconstrução  $\Psi_{4_V}$  e  $\Psi_{4_K}$ , optamos pelas seguintes medidas estatísticas:

- Erro absoluto relativo, descrito por meio do estudo Monte Carlo (ver na Seção 3.5);

$$\hat{\epsilon} = \frac{1}{10^4} \sum_{1 \leq i, j \leq 100} \left| \frac{f(i, j) - CM(i, j)}{f(i, j)} \right| \quad (4.1)$$

onde  $f(i, j)$  é o valor do pixel  $i, j$  na matriz representativa de  $f$  e  $CM(i, j)$  é o valor deste pixel resultante do processo de reconstrução aplicado ao conjunto de dados obtido da rede de sensores após as operações de amostragem, clusterização e agregação.

- Intervalo de confiança simétrico assintótico de 95% ( $\alpha_z = 1.96$ ) ou de 99% ( $\alpha_z = 2.576$ ), sempre que precisarmos verificar se duas medidas são ou não significativamente diferentes;

$$\left[ \mu - \alpha_z \frac{\sigma}{\sqrt{n}}; \mu + \alpha_z \frac{\sigma}{\sqrt{n}} \right] \quad (4.2)$$

onde  $\mu$  é a média do erro de reconstrução,  $\alpha_z$  é o quantil de ordem  $1 - \alpha/2$ ,  $\sigma$  é desvio padrão e  $n$  o número de valores examinados.

### 4.4 Legendas

Nesta seção apresentamos a padronização das legendas utilizada nos gráficos do erro de reconstrução gerados a partir dos nossos experimentos.

O padrão da linha distingue o tipo de situação sendo avaliada. Uma linha contínua representa a *situação1*. Uma linha tracejada indica a *situação2* e uma linha pontilhada trata da *situação2* com  $r_c = 15$  m.

Os símbolos representam as escalas  $s = \{5, 10, 15, 20\}$ .

As cores em azul representam reconstruções por Voronoi  $\Psi_{4_V}$ . Azul claro indica a reconstrução por Voronoi a partir da amostragem  $\Psi_1$ . A cor azul representa a reconstrução a partir da agregação dos dados amostrados por sensores clusterizados pela técnica de LEACH ( $\Psi_{3_L}$ ) e a cor azul escuro trata da reconstrução por Voronoi  $\Psi_{4_V}$  a partir da agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3_S}$ ).

As reconstruções por Kriging  $\Psi_{4_K}$  são representadas nas cores em vermelho. Vermelho claro representa a reconstrução por Kriging a partir da amostragem. Vermelho indica a reconstrução por Kriging a partir de  $\Psi_{3_L}$  e vermelho escuro trata da reconstrução por Kriging a partir de  $\Psi_{3_S}$ .

A figura 4.1 ilustra as legendas dos gráficos do erro de reconstrução em função dos processos pontuais.

Exemplificando, ao visualizarmos uma linha tracejada na cor azul escuro marcada com o símbolo circular, esta linha representa os resultados do erro de reconstrução por Voronoi a partir de  $\Psi_{3_S}$  (SKATER) considerando a *situação2* e o fenômeno na escala  $s = 5$ .

Legendas: Escalas-Reconstrução	
—	Situação1
---	Situação2
....	Situação2 com raio de comunicação $r_c = 15$ m
○	Escala 5
△	Escala 10
+	Escala 15
×	Escala 20
○ (azul)	Escala 5, reconstrução da amostragem por Voronoi
○ (azul)	Escala 5, reconstrução do Skater por Voronoi
○ (azul)	Escala 5, reconstrução do Leach por Voronoi
○ (vermelho)	Escala 5, reconstrução da amostragem por Kriging
○ (vermelho)	Escala 5, reconstrução do Skater por Kriging
○ (vermelho)	Escala 5, reconstrução do Leach por Kriging
× (azul)	Escala 20, reconstrução do Leach por Voronoi na <i>situação2</i>
× (azul)	Escala 20, reconstrução do Skater por Voronoi na <i>situação2</i> com $r_c = 15$ m
× (vermelho)	Escala 20, reconstrução do Leach por Kriging na <i>situação2</i>
× (vermelho)	Escala 20, reconstrução do Skater por Kriging na <i>situação2</i> com $r_c = 15$ m

Figura 4.1: Legendas dos Gráficos do Erro variando os Processos Pontuais

A figura 4.2 ilustra as legendas dos gráficos do erro de reconstrução em função das escalas. Nestas legendas, os processos pontuais  $a = \{-\infty, -30, -15, 0, 5, 1, 30\}$  são representados pelos símbolos.

Legendas: Processos Pontuais-Reconstrução	
⊠	30
▽	15
◇	5
×	0
+	-15
△	-30
○	$-\infty$

Figura 4.2: Legendas dos Gráficos do Erro variando as Escalas

Exemplificando novamente, ao visualizarmos uma linha contínua na cor vermelho claro marcada com o símbolo circular, tal linha representa os resultados do erro de reconstrução por Kriging obtidos a partir da amostragem  $\Psi_1$  considerando a *situação1* e o processo pontual regular ( $a = -\infty$ ).

## 4.5 Resultados e Avaliações para a Situação1

Nesta seção mostramos e analisamos alguns resultados da reconstrução do fenômeno iluminação obtidos ao aplicarmos os dois processos de reconstrução modelados neste trabalho, Voronoi  $\Psi_{4V}$  e Kriging  $\Psi_{4K}$ , aos três conjuntos de dados: (i) amostragens individuais dos sensores ainda não clusterizados ( $\Psi_1$ ), (ii) agregação dos dados amostrados por sensores clusterizados pela técnica de LEACH ( $\Psi_{3L}$ ) e (iii) agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3S}$ ).

Uma vez que nossas simulações tratam da amostragem, clusterização, agregação e por fim aplicam os processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  para reconstruir o fenômeno iluminação  $f$  e avaliar a qualidade desses processos, podemos considerar a *situação1* com o processo de reconstrução  $\Psi_{4V}$  como um caso base da análise do erro de reconstrução uma vez que ao amostrarmos e reconstruirmos utilizando Voronoi podemos atribuir o erro obtido especificamente aos fatores apresentados na Seção 3.1, página 15. Ao incluirmos para a *situação1* um outro processo de reconstrução,  $\Psi_{4K}$ , criamos a oportunidade de avaliar a qualidade da reconstrução entre diferentes técnicas de reconstrução aplicadas aos mesmos conjuntos de dados  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$ .

As operações de amostragem, clusterização e agregação realizadas pela rede de sensores na *situação 1* foram modeladas nas Seções 3.3.5.1 (página 25), 3.3.6.1 (página 26) e 3.3.7 (página 29), respectivamente.

Na *Situação 1*, o processo de amostragem utiliza o diagrama de Voronoi para particionar a área sob observação e assim definir as áreas de percepção dos sensores (para maiores detalhes sobre as características modeladas para os sensores *tipo 1*, ver Seção 3.3.4). Considerando a questão da cobertura de percepção ou monitoramento do fenômeno, podemos dizer que o modelo de amostragem  $\Psi_1$  da *situação 1*, embora afastado da realidade, apresenta-se como *ótimo* no sentido que 100% da área é percebida pela rede de sensores.

A figura 4.3 ilustra uma ocorrência de todo o processo sob estudo: a figura 4.3(a) mostra o fenômeno iluminação  $f$  em observação e na figura 4.3(b) ilustramos as área de percepção de cada sensor com sendo a célula de Voronoi a ele associada.

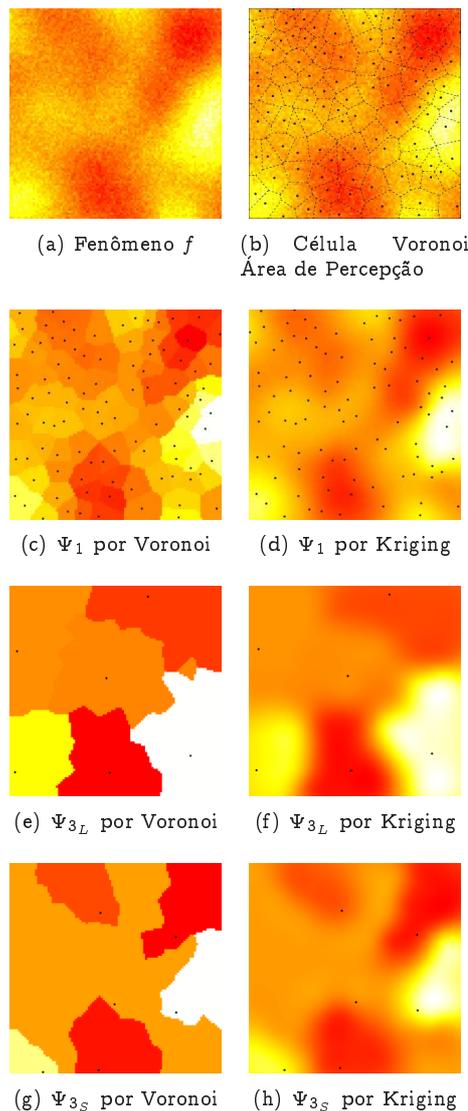


Figura 4.3: Reconstruções  $\Psi_4$  a partir de  $\Psi_1$ ,  $\Psi_{3L}$  e de  $\Psi_{3S}$  - 100 sensores na *situação 1*

As figuras 4.3(c), 4.3(e) e 4.3(g) ilustram a reconstrução do fenômeno  $f$  ao aplicarmos o processo de reconstrução por Voronoi  $\Psi_{4V}$  aos três conjuntos. Nas figuras 4.3(d), 4.3(f) e 4.3(h) ilustramos a reconstrução do fenômeno  $f$  resultante da aplicação do processo de reconstrução por Kriging  $\Psi_{4K}$  aos mesmo três conjuntos,  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$ . Nas ilustrações da figura 4.3, o fenômeno foi gerado com a escala  $s = 20$  e processo pontual repulsivo  $a = -30$  com 100 sensores.

A seguir, no contexto da *situação 1* e com base nas medidas de avaliação definidas na Seção 4.3, apresentamos algumas avaliações, descritas na tabela 4.1, dos estimadores média e variância dos erros de reconstrução do fenômeno  $f$  resultantes da aplicação dos processos de reconstrução por Voronoi  $\Psi_{4V}$

e por Kriging  $\Psi_{4_K}$ . Estes processos foram aplicados para cada uma das 100 replicações das possíveis combinações das escalas  $s = \{5, 10, 15, 20\}$  com os processos pontuais  $a \in \{-\infty, -30, -15, 0, 5, 15, 30\}$  (para maior detalhes sobre o estudo Monte Carlo, ver Seção 3.5 na página 40).

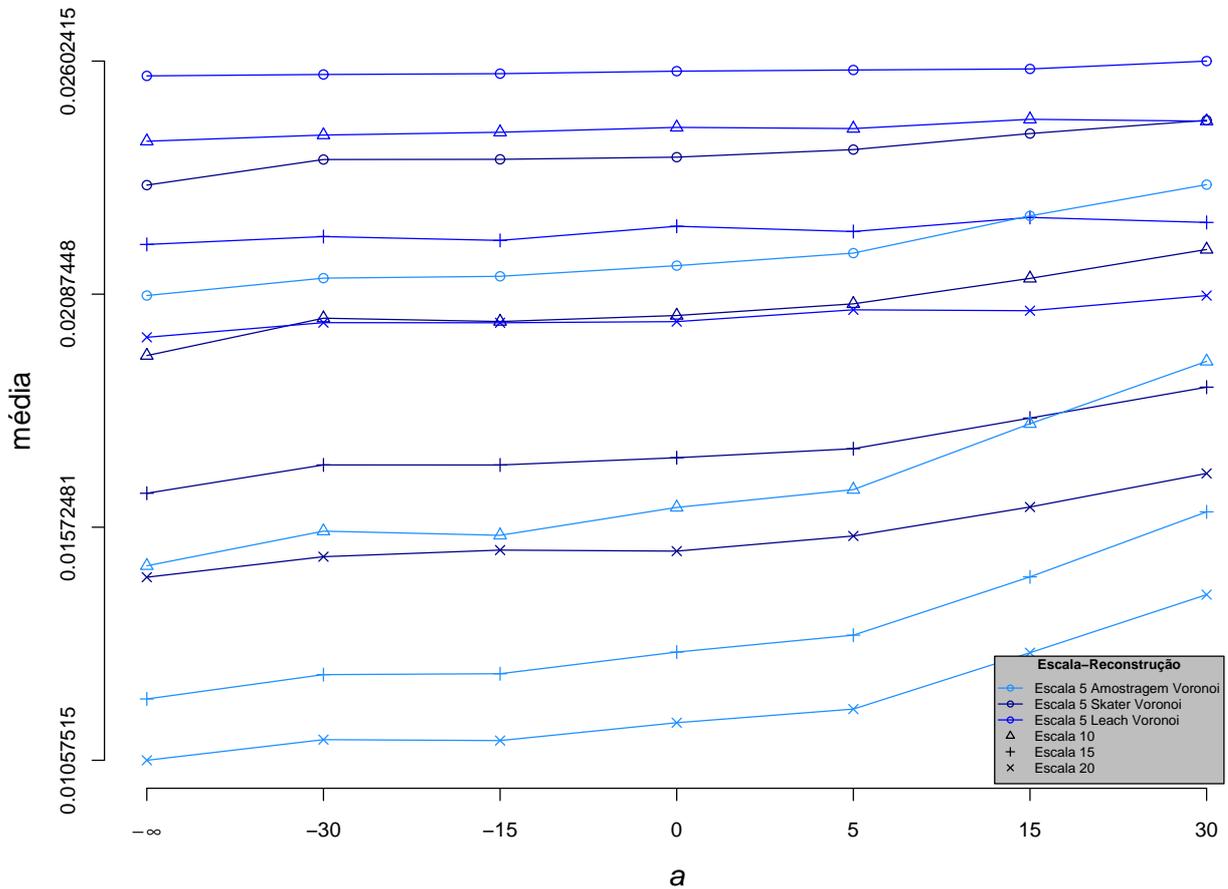


Figura 4.4: Média do erro de Reconstrução por Voronoi a partir de  $\Psi_1$ ,  $\Psi_{3_L}$  e  $\Psi_{3_S}$  - Situação 1

Considerando a utilização do processo de reconstrução por Voronoi  $\Psi_{4_V}$ , a figura 4.4 mostra que, para todos os processos pontuais  $a \in \{-\infty, -30, -15, 0, 5, 15, 30\}$  e todas as escalas  $s \in \{5, 10, 15, 20\}$ , os processos de agregação sobre os dados clusterizados  $\Psi_{3_L}$  e  $\Psi_{3_S}$  realizados pela rede de sensores impõem um maior nível de erro à qualidade da reconstrução do fenômeno observado quando comparados com a reconstrução a partir da amostragem individual dos sensores  $\Psi_1$ . Além disto, percebemos que a reconstrução a partir de  $\Psi_{3_S}$  é invariavelmente melhor que a reconstrução a partir de  $\Psi_{3_L}$ , uma vez que SKATER diferentemente do LEACH leva em conta a correlação entre os dados.

Outra constatação é a perda de qualidade ou maior nível de erro da reconstrução à medida que a distribuição dos sensores vai se tornando mais atrativa, e à medida que a escala vai diminuindo, ou seja, a perda de qualidade da reconstrução é diretamente proporcional à atratividade da distribuição dos sensores e inversamente proporcional à escala (quanto maior a escala menor a granularidade do fenômeno sob observação e melhor a qualidade da reconstrução).

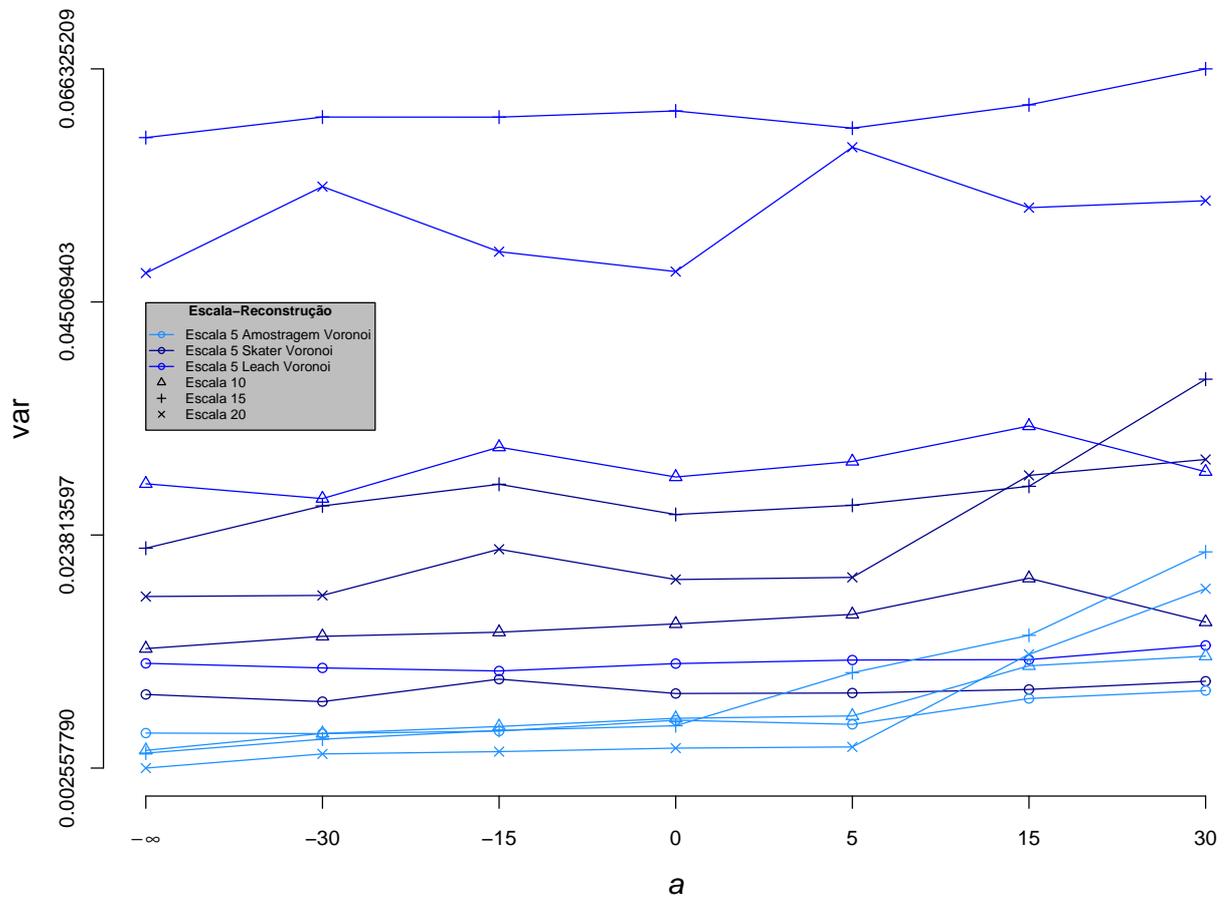


Figura 4.5: Variância do erro de Reconstrução por Voronoi a partir de  $\Psi_1$ ,  $\Psi_{3_L}$  e  $\Psi_{3_S}$  - Situação 1

Ainda com relação ao processo de reconstrução por Voronoi, a partir da figura 4.5, considerando todas as escalas  $s \in \{5, 10, 15, 20\}$ , observamos uma maior variância do erro de reconstrução a partir da agregação dos dados clusterizados pelo LEACH ( $\Psi_{3_L}$ ), quando comparada com a variância a partir de  $\Psi_{3_S}$  (SKATER). Isto ocorre uma vez que o LEACH, ao não considerar a correlação dos dados, forma *clusters* menos homogêneos que o SKATER, ou seja, diferentemente do SKATER os sensores membros de um *cluster* formado pelo LEACH podem apresentar dados de amostragem com pouco ou nenhuma correlação entre si, levando a uma maior perda de informação durante a agregação e como consequência a uma menor qualidade da reconstrução do fenômeno sendo observado.

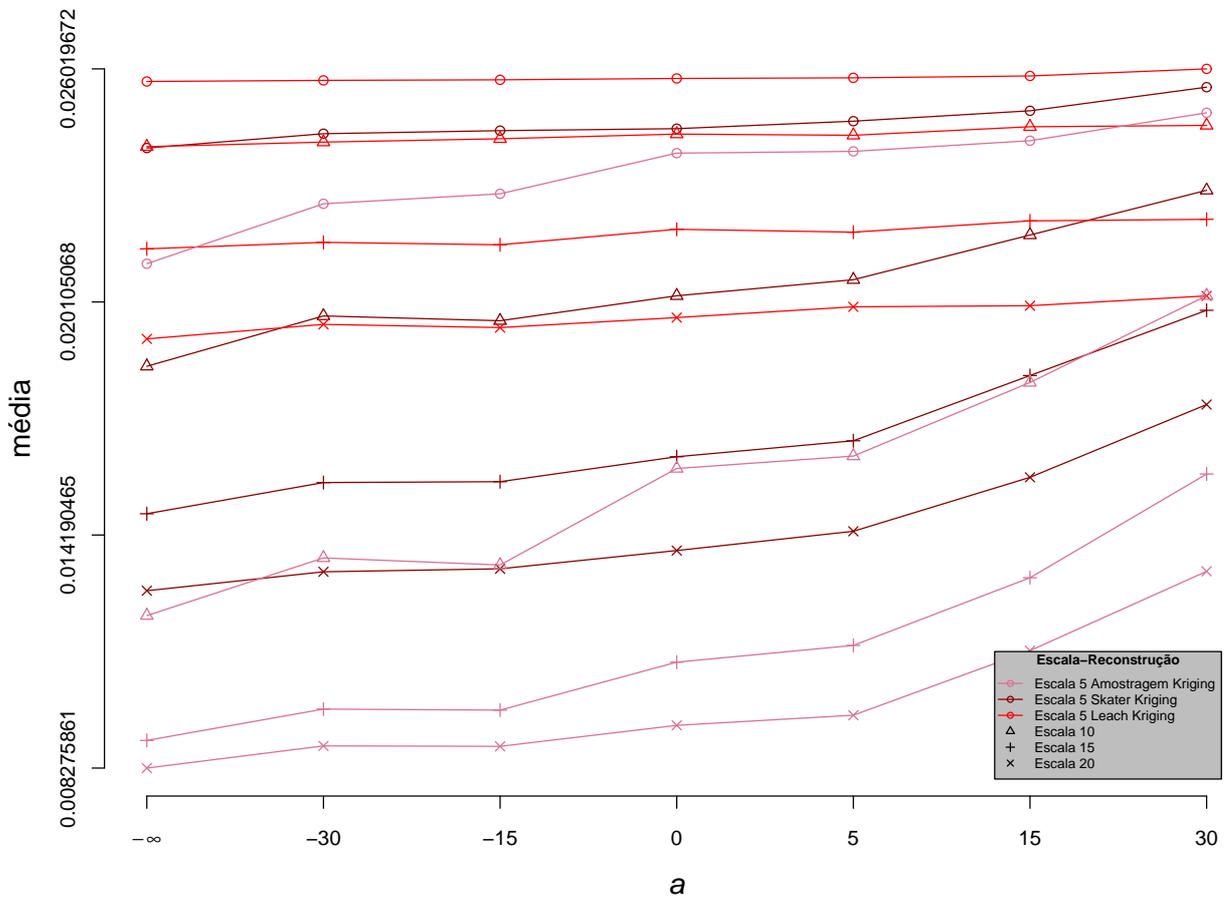


Figura 4.6: Média do erro de Reconstrução por Kriging a partir de  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$  - Situação 1

Considerando agora a utilização do processo de reconstrução por Kriging  $\Psi_{4K}$ , a partir da figura 4.6 podemos extrair conclusões semelhantes às obtidas a partir da figura 4.4.

Para todos os processos pontuais  $a \in \{-\infty, -30, -15, 0, 5, 15, 30\}$  e considerando todas as escalas  $s \in \{5, 10, 15, 20\}$ , a qualidade da reconstrução é crescente na seguinte ordem:  $\Psi_{3L}$ ,  $\Psi_{3S}$  e  $\Psi_1$ . A atratividade de distribuição dos sensores (sendo o processo mais atrativo para  $a = 30$ ) afeta a qualidade da reconstrução de forma inversamente proporcional, enquanto a escala mantém em relação de proporcionalidade direta com a qualidade de reconstrução, ou seja, processos pontuais mais atrativos resultam em menores qualidades da reconstrução e maiores escalas (ou menores granularidades) resultam em maiores qualidades da reconstrução.

Conferindo os intervalos de confiança (95% e 99%), definidos na Seção 4.3, comparamos de forma mais rigorosa os desempenhos entre  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$ . A reconstrução a partir de  $\Psi_{3S}$  obteve melhor êxito que  $\Psi_{3L}$  para todos os processos pontuais e para todas as escalas, no entanto pelo intervalo de confiança de 95% não podemos dizer que as medidas para o caso  $a = 30$  e  $s = 5$  defirem significativamente. Pelo intervalo de confiança de 99%, não podemos dizer que entre  $\Psi_1$  e  $\Psi_{3S}$  haja diferenças significativas para os casos de processos pontuais  $a \in \{0, 5, 30\}$  na escala  $s = 5$ .

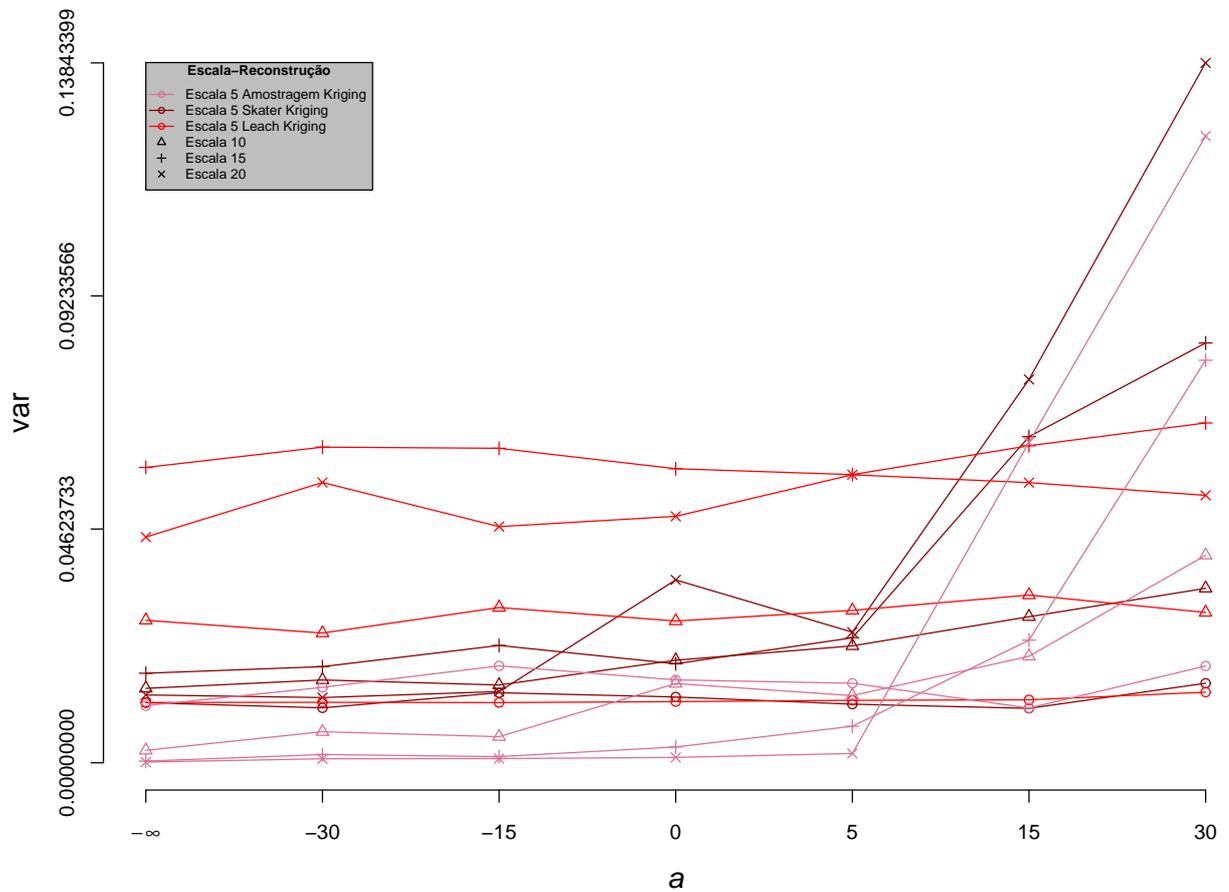


Figura 4.7: Variância do erro de Reconstrução por Kriging a partir de  $\Psi_1$ ,  $\Psi_{3_L}$  e  $\Psi_{3_S}$  - Situação 1

Considerando os processo pontuais atrativos  $a \in \{5, 15, 30\}$ , embora a reconstrução por Kriging para esses processo pontuais nas escalas menores  $s \in \{5, 10\}$  apresente maiores erros que a reconstrução para as escalas maiores  $s \in \{15, 20\}$ , conforme evidenciado na figura 4.6, observamos na figura 4.7 que, nos erros de reconstrução por Kriging a partir de  $\Psi_1$  (Amostragem) e de  $\Psi_{3_S}$  (SKATER), quanto menor a escala, menor é o aumento da variação do erro de reconstrução a medida que o processo pontual for se tornando mais atrativo. Quanto menor a escala, maior é a dificuldade imposta aos processos de amostragem, clusterização e agregação e como consequência menores são as diferenças de qualidade de reconstrução a partir de  $\Psi_1$  e  $\Psi_{3_S}$  entre os processos pontuais. Por outro lado, quanto maior a escala, mais acentuadas são essas diferenças. Isto não é observado com relação a  $\Psi_{3_L}$ , um vez que o LEACH, ao não levar em consideração a correlação entre os dados criando *cluster* apenas com base na relação espacial entre os sensores, apresenta qualidade de reconstrução similar entre todos os processos pontuais para cada escala.

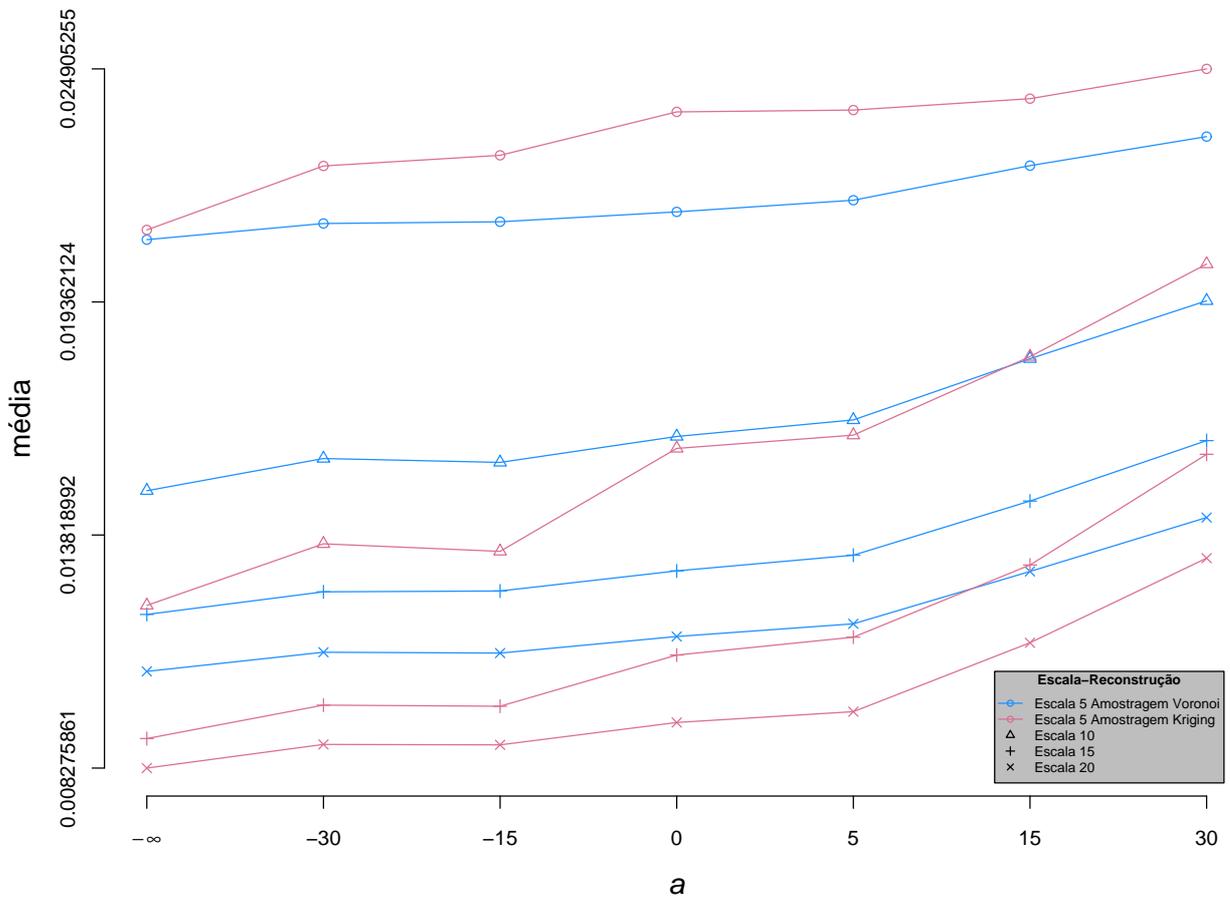


Figura 4.8: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_1$  - Situação 1

A figura 4.8 compara os desempenhos dos dois processos de reconstrução, Voronoi  $\Psi_{4V}$  e Kriging  $\Psi_{4K}$ , quanto a qualidade de reconstrução de fenômeno  $f$  a partir dos dados de amostragem individual  $\Psi_1$  dos sensores.

Percebemos que ambos os processos de reconstrução perdem qualidade a medida que o processo pontual vai se tornando mais atrativo.

O processo de reconstrução por Kriging  $\Psi_{4K}$  apresenta melhores resultados que o processo de reconstrução por Voronoi  $\Psi_{4V}$  para as escalas maiores  $s = \{15, 20\}$ . Entre os processo pontuais  $a = \{0, 5, 15\}$  da escala  $s = 10$ , os desempenhos dos dois processos de reconstrução se aproximam, e ao calcularmos os intervalos de confiança de 99% não podemos dizer que as medidas difererem significativamente. O processo de reconstrução por Voronoi  $\Psi_{4V}$  passa a apresentar melhores resultados que o processo de reconstrução por Kriging  $\Psi_{4K}$  para a escala  $s = 10$  com processo pontual  $s = 30$  e para toda a escala  $s = 5$ .

Na figura 4.9 ilustramos a perda de qualidade na reconstrução por Kriging em relação a reconstrução por Voronoi na escala  $s = 10$  a medida que o processo pontual se torna mais atrativo.

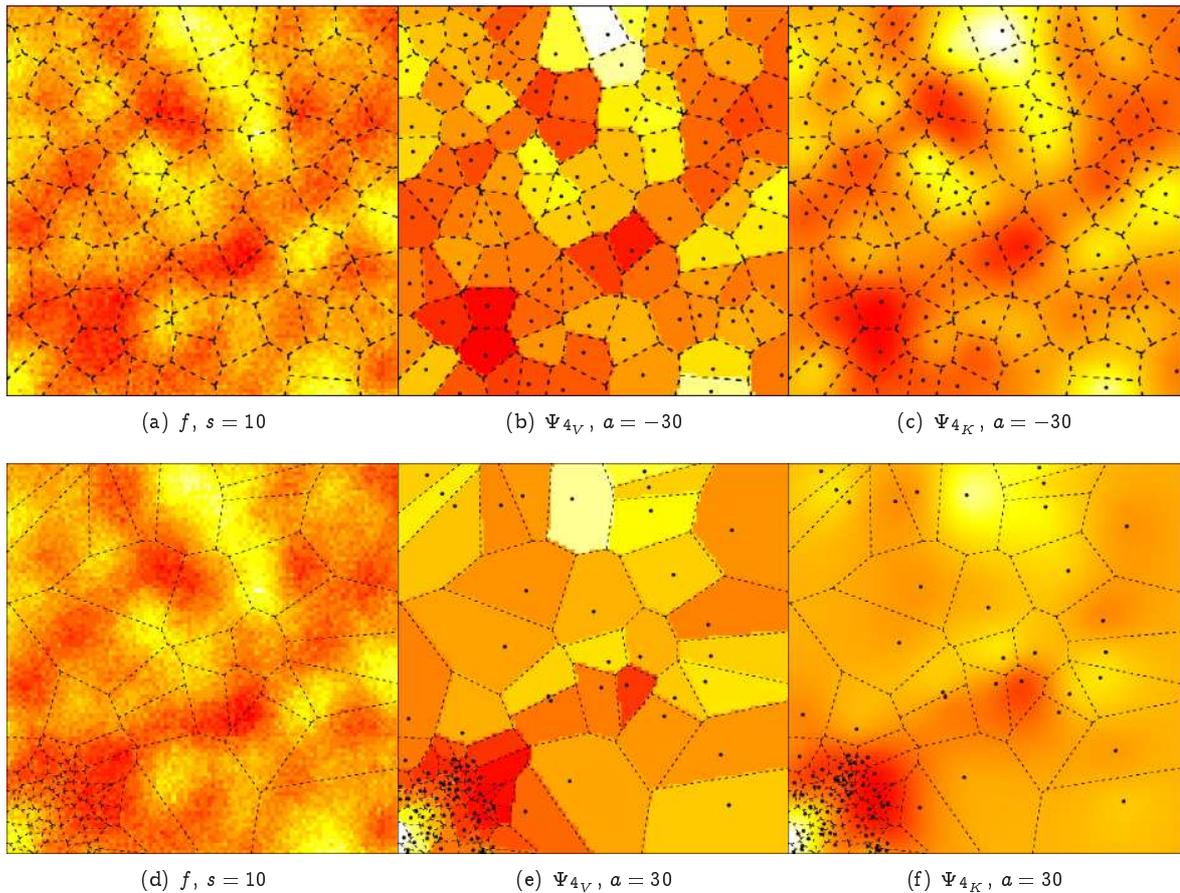


Figura 4.9: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_1$  na escala  $s = 10$

Nas figuras 4.9(a), 4.9(b) e 4.9(c) ilustramos o fenômeno  $f$ , a reconstrução por Voronoi  $\Psi_{4V}$  a partir de  $\Psi_1$  e a reconstrução por Kriging  $\Psi_{4K}$  a partir de  $\Psi_1$ , respectivamente, para o processo pontual repulsivo  $a = -30$ .

As figuras 4.9(d), 4.9(e) e 4.9(f) ilustram o fenômeno  $f$ , a reconstrução por Voronoi  $\Psi_{4V}$  a partir de  $\Psi_1$  e a reconstrução por Kriging  $\Psi_{4K}$  a partir de  $\Psi_1$ , respectivamente, no entanto para o processo pontual atrativo  $a = 30$ .

Em todas as figuras foi incluído o particionamento da área pelo diagrama de Voronoi, com o objetivo de ressaltar as diferenças entre as reconstruções. Notemos que para o processo pontual atrativo  $a = -30$ ,  $\Psi_{4K}$  reconstrói os contornos característicos do fenômeno melhor que a reconstrução por Voronoi  $\Psi_{4V}$ . Por outro lado, para o processo atrativo  $s = 30$ ,  $\Psi_{4K}$  já não consegue a mesma qualidade de reconstrução a partir dos dados enviados pelos sensores fora da área com maior densidade de sensores (ver o canto inferior direito da figura 4.9(f)), passando  $\Psi_{4V}$  a apresentar, em média, melhor qualidade de reconstrução do fenômeno  $f$ .

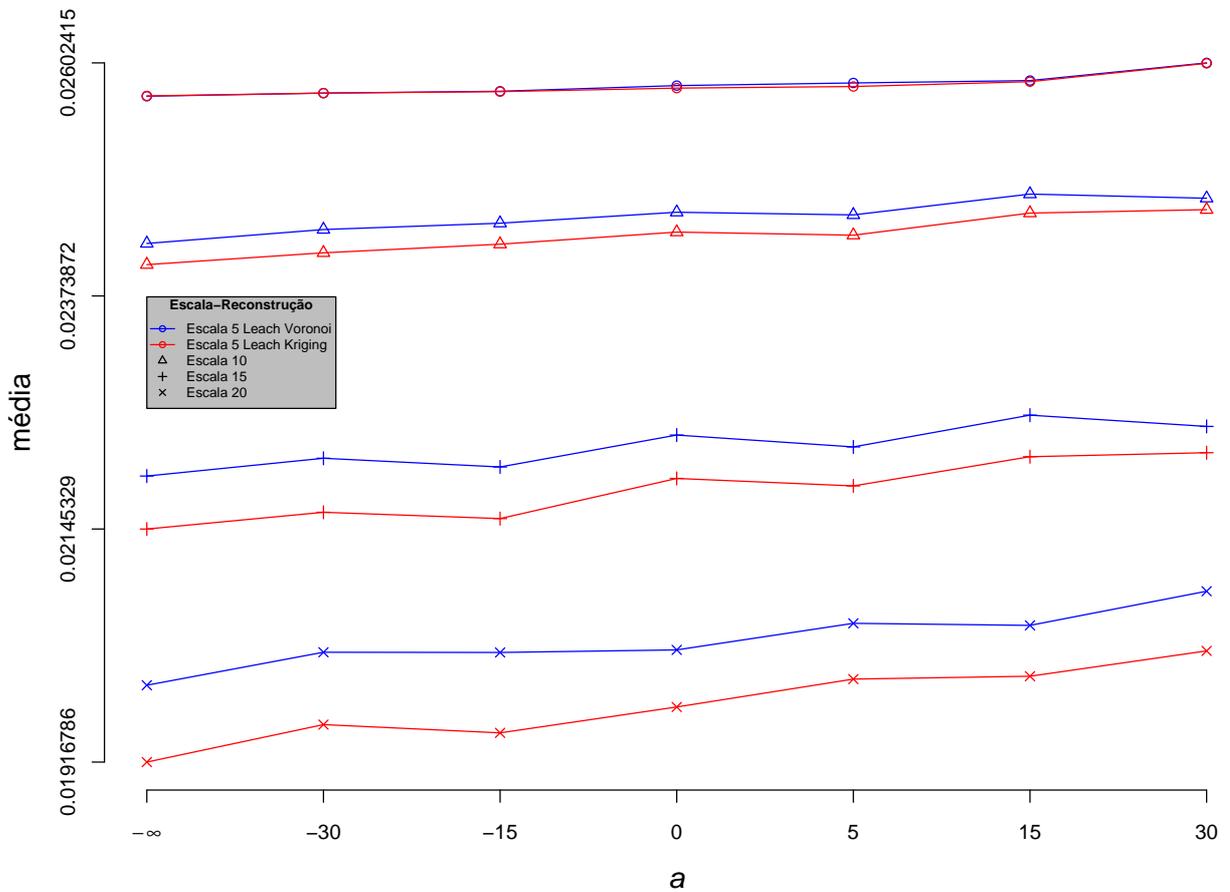


Figura 4.10: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3L}$  - Situação 01

A figura 4.10 compara os desempenhos dos dois processos de reconstrução, Voronoi  $\Psi_{4V}$  e Kriging  $\Psi_{4K}$ , quanto a qualidade de reconstrução de fenômeno  $f$  a partir da agregação dos dados amostrados por sensores clusterizados pela técnica de LEACH ( $\Psi_{3L}$ ).

Embora observamos pela figura que a reconstrução por Kriging  $\Psi_{4K}$  apresente menores erros que a reconstrução por Voronoi para as escalas  $s = \{10, 15, 20\}$ , pelos intervalos de confiança de 95% e 99% não podemos dizer que as medidas diferem significativamente.

Um vez que o LEACH não considera a correlação entre os dados para a formação dos *clusters*, analisando cada escala percebemos que tanto a reconstrução por Voronoi quanto a reconstrução por Kriging não apresentam perdas ou ganhos expressivos ao variarmos os processos pontuais. Embora visualmente percebamos uma leve tendência de crescimento do erro de reconstrução com a atratividade, por ambos os testes de intervalo de confiança não podemos dizer que os valores diferem significativamente, exceto ao compararmos os valores entre os estimadores do erro de reconstrução por Kriging para  $\{a = -\infty, s = 20\}$  e  $\{a = 30, s = 20\}$ .

Na figura 4.11 ilustramos a reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  do fenômeno iluminação com escala  $s = 20$  a partir de  $\Psi_{3L}$ .

Percebemos que, mesmo na escala  $s = 20$  onde ocorre a maior diferença entre o desempenho de reconstrução por Voronoi e por Kriging conforme a figura 4.10, independentemente dos processos pontuais  $a = -\infty$  (repulsivo) e  $a = 30$  (atrativo), a qualidade da reconstrução do fenômeno  $f$  por  $\Psi_{4V}$  e por  $\Psi_{4K}$  não apresentam diferenças marcantes. Este comportamento tende a se intensificar a medida que diminuimos a escala, ou seja, a medida que a granularidade do fenômeno aumenta.

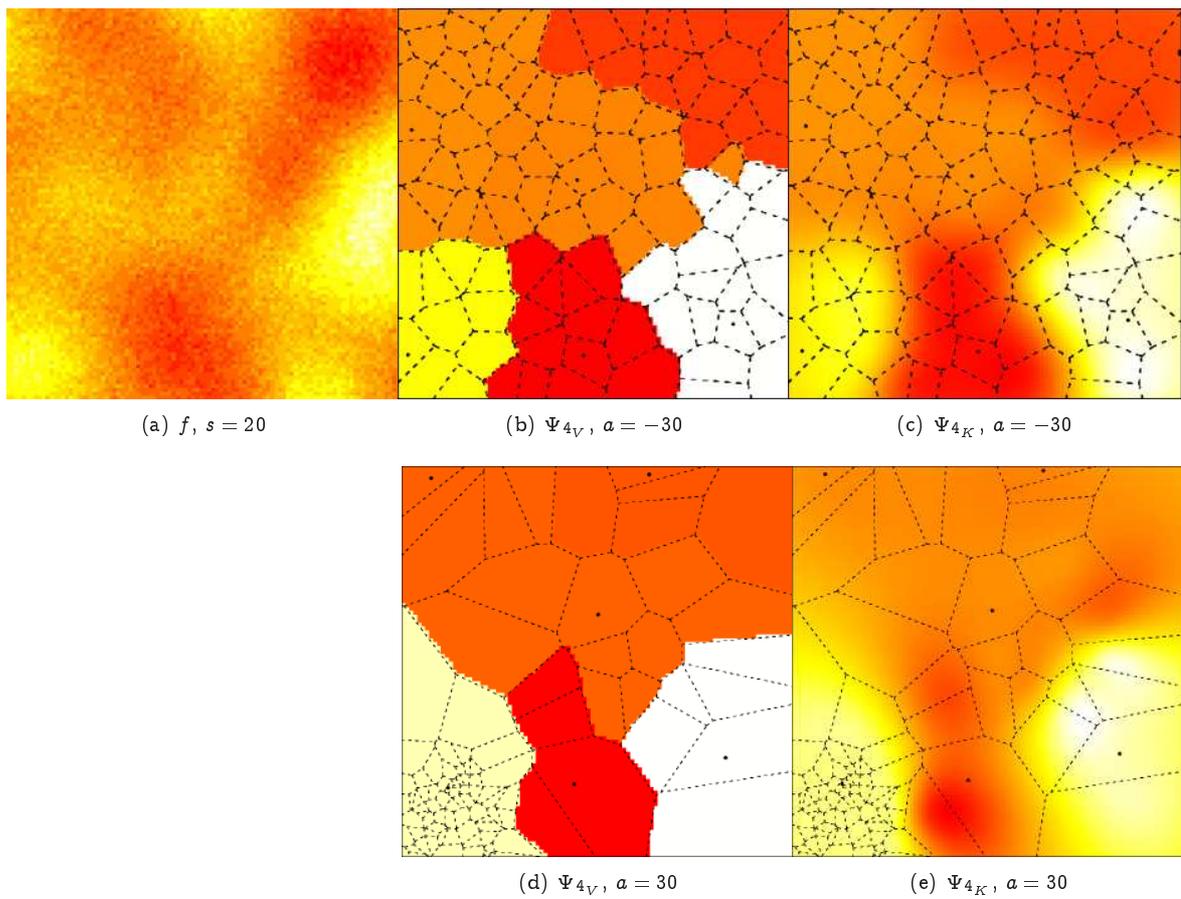


Figura 4.11: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_{3L}$  na escala  $s = 20$

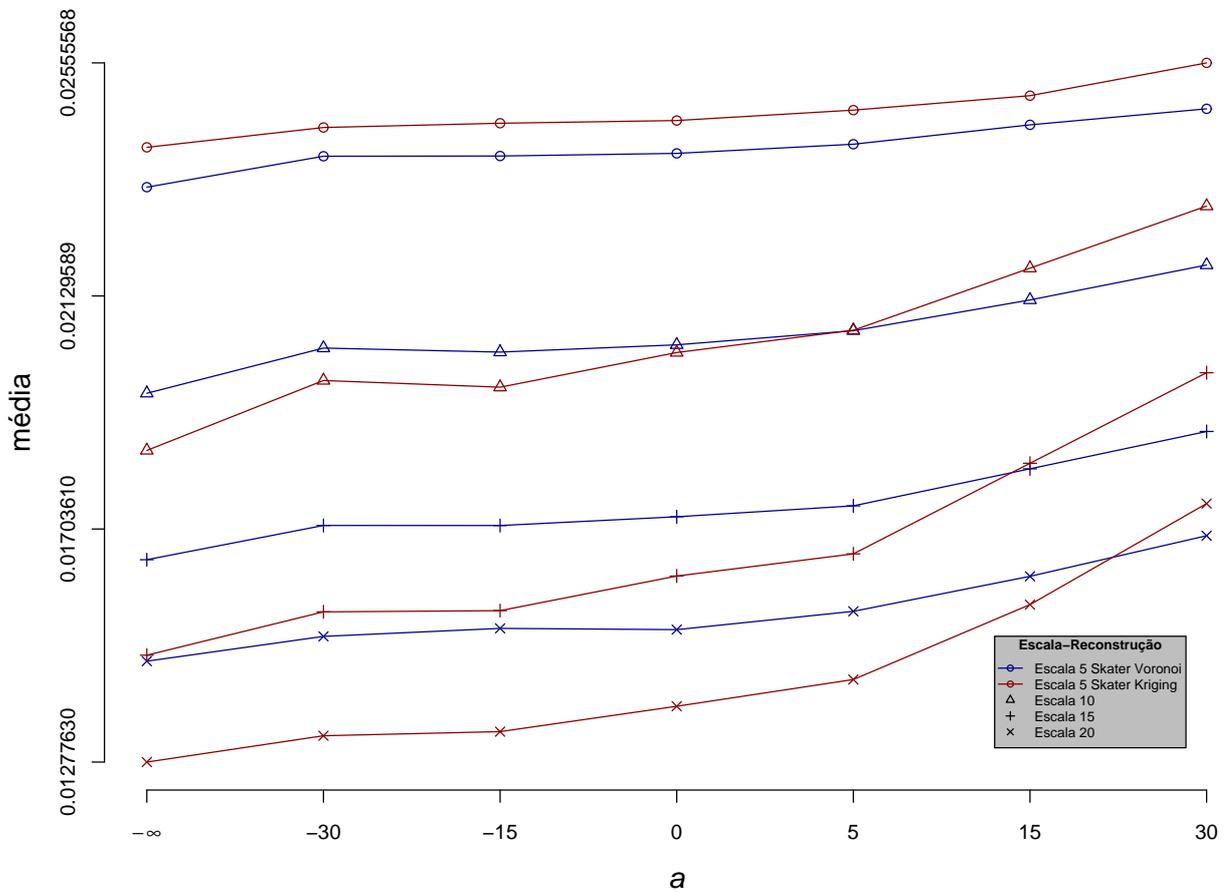


Figura 4.12: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3S}$  - Situação 1

A figura 4.12 compara os desempenhos dos dois processos de reconstrução, Voronoi  $\Psi_{4V}$  e Kriging  $\Psi_{4K}$ , quanto a qualidade de reconstrução de fenômeno  $f$  a partir da agregação dos dados amostrados por sensores clusterizados pela técnica de SKATER ( $\Psi_{3S}$ ).

Através desta figura constatamos que para a escala  $s = 5$  o processo de reconstrução por Voronoi  $\Psi_{4V}$  obtém invariavelmente melhores resultados que o processo de reconstrução por Kriging  $\Psi_{4K}$  para todos os pontuais. De acordo com os intervalos confiança de 99%, podemos dizer que os valores comparados diferem significativamente.

Para os processos pontuais  $a = \{-\infty, -30, -15, 0, 5\}$  nas maiores escalas  $s = \{15, 20\}$ , o processo de reconstrução por  $\Psi_{4K}$  obteve melhor qualidade ou menores erros que  $\Psi_{4V}$ , uma vez que a reconstrução por Kriging conseguiu estimar melhor o fenômeno  $f$  a partir de  $\Psi_{3S}$ . No entanto, ainda nessas escalas e muito embora pelos intervalos de confiança de 99% não possamos afirmar que haja diferenças significativas, o processo de reconstrução por Kriging não mais apresenta melhores resultados que  $\Psi_{4V}$  para os processos atrativos  $a = \{15, 30\}$ .

A figura 4.13 ilustra a reconstrução, por Voronoi e por Kriging, do fenômeno iluminação com escala  $s = 20$  para os processos pontuais repulsivo  $a = -30$  e atrativo  $s = 30$ .

Observando as figuras 4.13(b) e 4.13(c), podemos perceber que a reconstrução por Kriging  $\Psi_{4K}$  tende a capturar melhor os contornos característicos do fenômeno  $f$  sendo reconstruído.

Pelas figuras 4.13(d) e 4.13(e), percebemos ser mais difícil uma comparação visual entre a qualidade da reconstrução por  $\Psi_{4V}$  e por  $\Psi_{4K}$ . Confrontar estas figuras com as figuras 4.13(b) e 4.13(c) evidencia a perda de qualidade que a atratividade impôs aos processos de amostragem, agregação, clusterização e reconstrução.

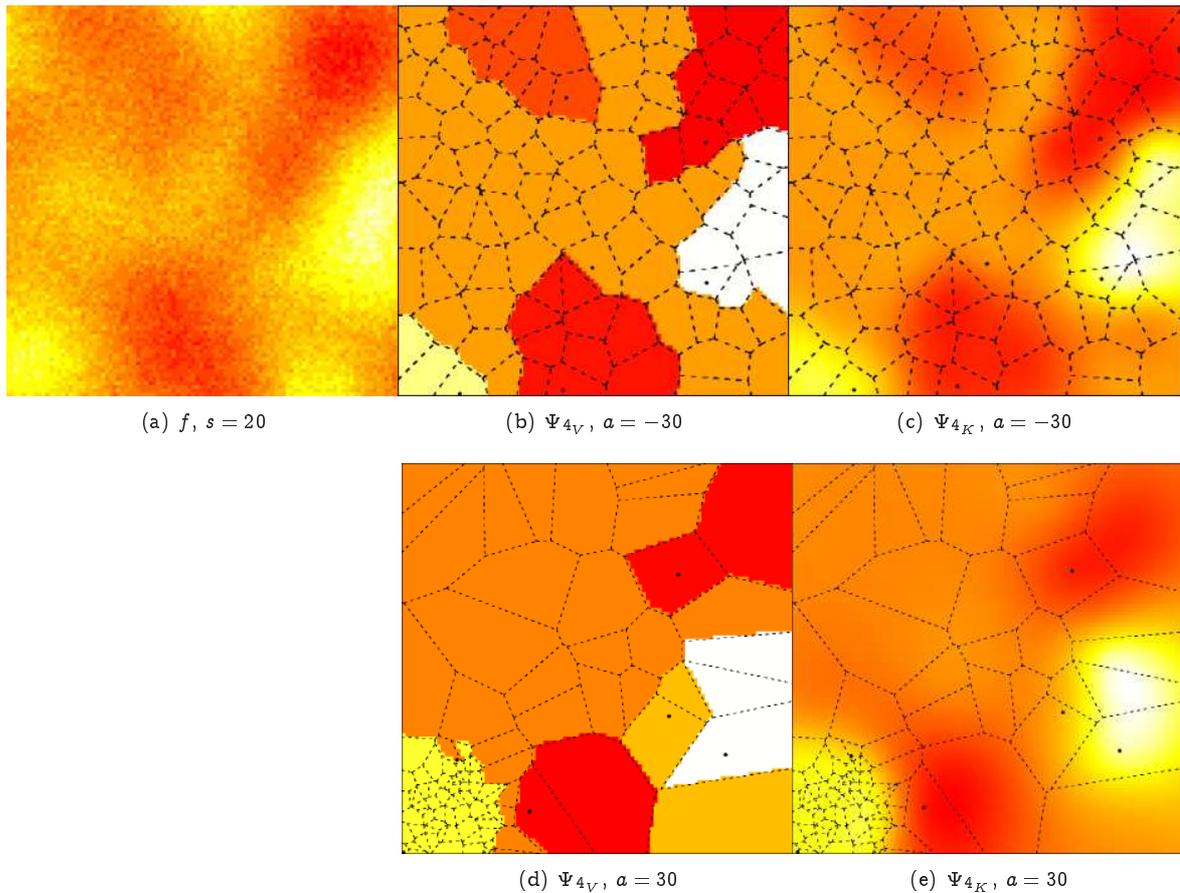


Figura 4.13: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_{3S}$  na escala  $s = 20$

Ainda analisando a figura 4.12, percebemos que para a escala  $s = 10$ , a reconstrução por Kriging  $\Psi_{4K}$  obteve os melhores resultados para os processos pontuais  $a = \{-\infty, -30, -15\}$  ao passo que a reconstrução por Voronoi obteve melhores resultados para o processo pontual mais atrativo  $a = 30$ . Para os processos pontuais  $a = \{0, 5, 15\}$  dessa escala não podemos concluir qual dos processo de reconstrução obteve os melhores resultados, uma vez que pelos intervalos de confiança de 99% não poderemos afirmar que os valores diferem significativamente.

A figura 4.14 ilustra os diferentes comportamentos quanto à qualidade de reconstrução obtidas por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  para a escala  $s = 10$  e os processos pontuais  $a = -30$  (repulsivo) e  $a = 30$  (atrativo).

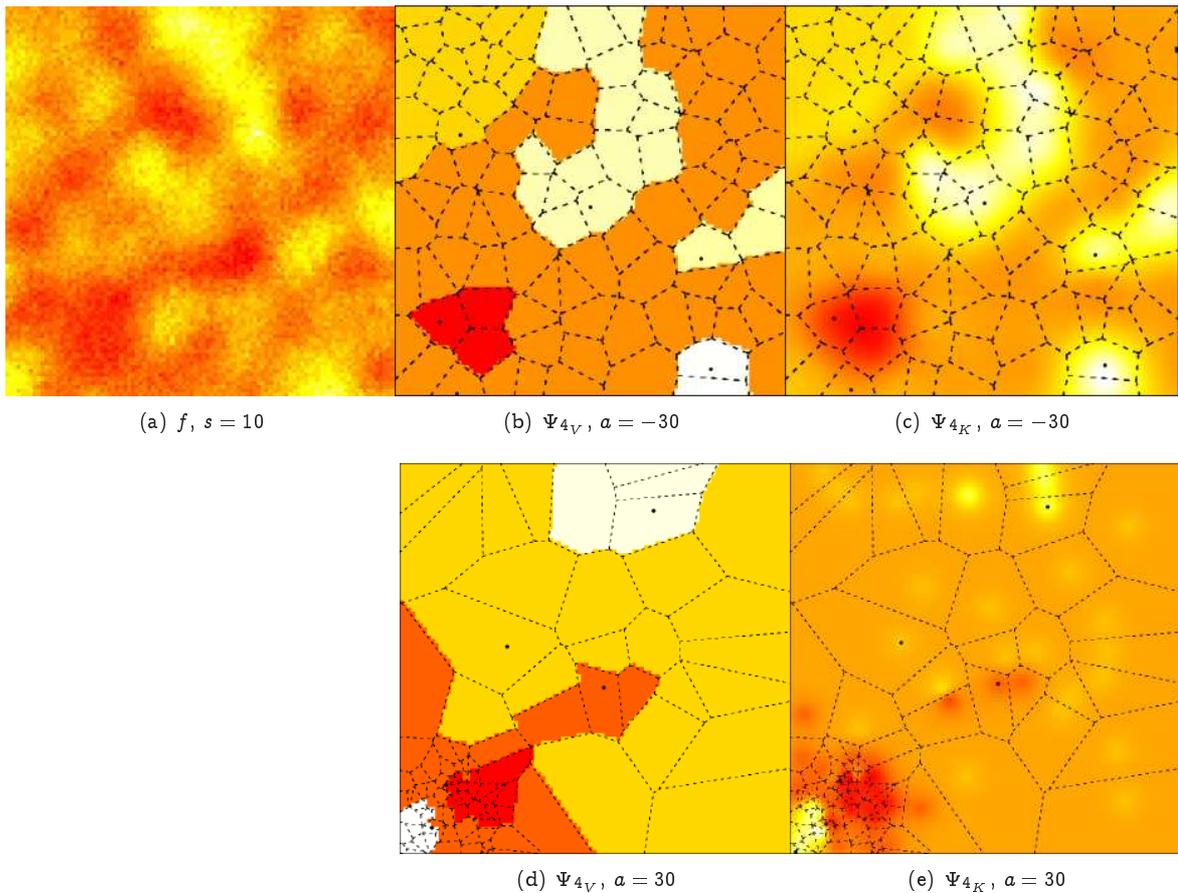


Figura 4.14: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_{3S}$  na escala  $s = 10$

Pelas figuras 4.14(b) e 4.14(c) percebemos uma maior suavidade na reconstrução por Kriging do fenômeno  $f$  quando comparada a reconstrução por Voronoi. Esta maior suavidade é inerente à estimação pelo Kriging, e leva a uma melhor qualidade da reconstrução.

As figuras 4.14(d) e 4.14(e), ilustram a perda de qualidade imposta pela atratividade a ambos os processos de reconstrução. No entanto, podemos visualizar que o processo de reconstrução por Kriging sofreu maiores impactos. Isto ocorre pois na reconstrução por Kriging a estimação do fenômeno com base nas informações recebidas por um *cluster head* fora da área de maior densidade de sensores (quanto inferior esquerdo) é influenciada pelas informações dos *clusters* vizinhos, já que o Kriging estima o fenômeno  $f$  por meio de uma superfície. Por não ocorrer esta influência na reconstrução por Voronoi, os resultados obtidos por  $\Psi_{4V}$  para o processo atrativo são, em média, melhores.

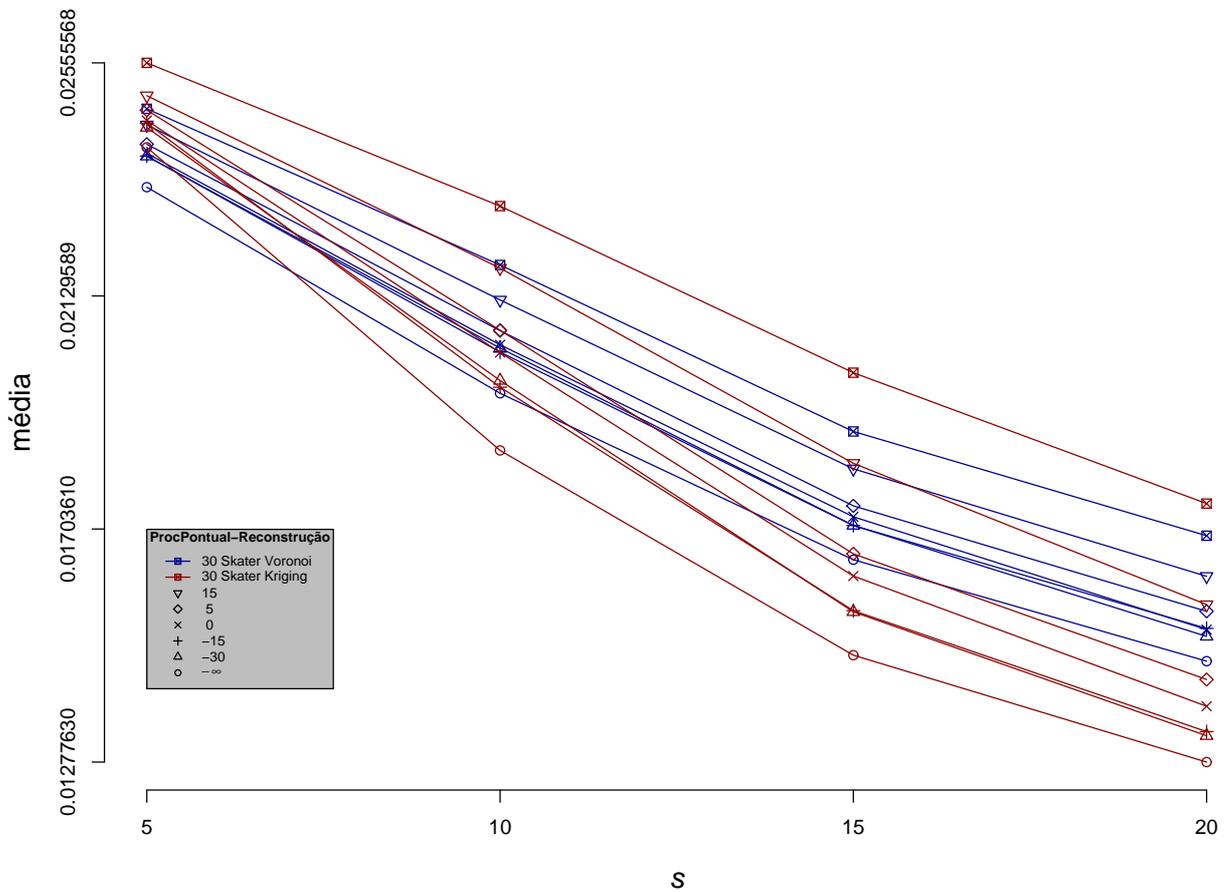


Figura 4.15: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3s}$  - Situação1

Apresentamos a figura 4.15 mostrando que, indiferentemente do processo pontual, tanto o processo de reconstrução por Voronoi  $\Psi_{4V}$  quanto o processo de reconstrução por Kriging  $\Psi_{4K}$  tendem a aumentar a qualidade de reconstrução à medida que a escala  $s$  for aumentando, ou seja, a medida que a granularidade do fenômeno for diminuindo.

Finalizamos a análise isolada da *situação1* apresentamos a seguir alguns resultados de reconstrução por Voronoi e por Kriging obtidos a partir dos três conjuntos de dados  $\Psi_1$ ,  $\Psi_{3s}$  e  $\Psi_{3L}$  considerando a escala  $s = 20$  e todos os processos pontuais  $a = \{-\infty, -30, -15, 0, 5, 15, 30\}$ .

A figura 4.16 ilustra a reconstrução por Voronoi  $\Psi_{4V}$  do fenômeno iluminação  $f$  a partir dos dados de amostragem individual  $\Psi_1$  de 100 sensores. A figura 4.16(a) ilustra  $f$  e as demais ilustram os processos pontuais  $a$ . Percebemos uma diminuição na qualidade de ambos os processos de reconstrução a medida que o processo vai se tornando mais atrativo.

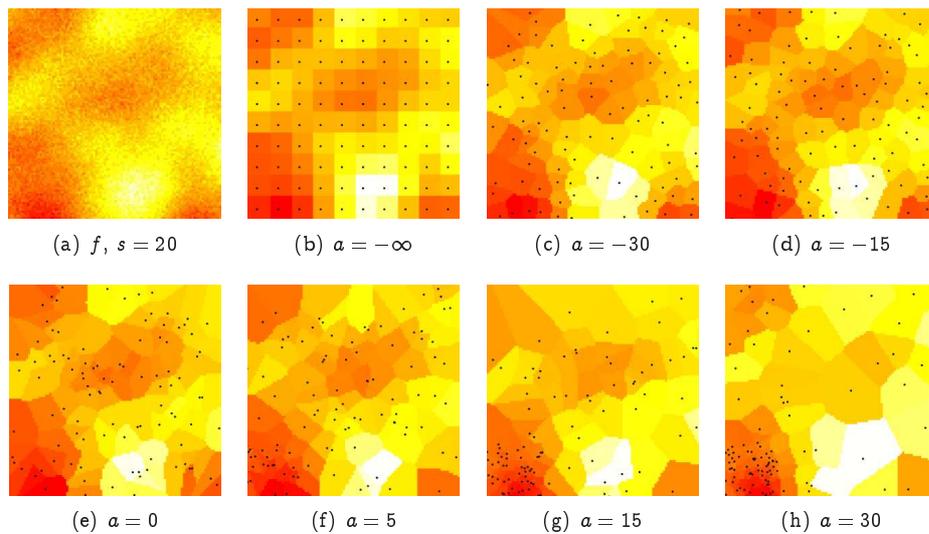


Figura 4.16: Reconstruções  $\Psi_{4V}$  a partir de  $\Psi_1$  - 100 sensores na *situação 1*

Na figura 4.17 ilustramos a reconstrução por Kriging  $\Psi_{4K}$  do fenômeno iluminação  $f$  a partir dos mesmos dados de amostragem individual  $\Psi_1$  dos sensores utilizados na reconstrução da figura 4.16.

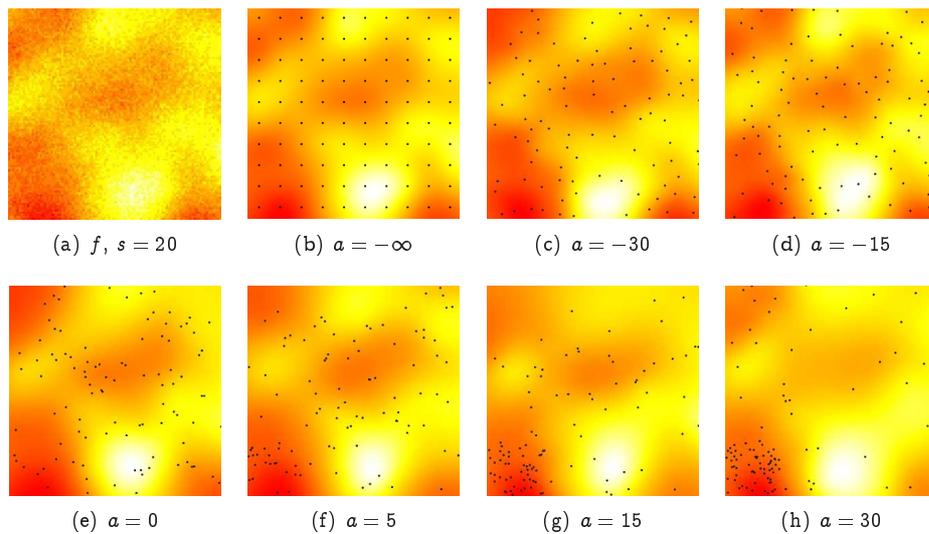


Figura 4.17: Reconstruções  $\Psi_{4K}$  a partir de  $\Psi_1$  - 100 sensores na *situação 1*

Igualmente à reconstrução a partir das amostragens individuais dos sensores, na reconstrução a partir dos dados processados pela rede de sensores (amostragem, clusterização e agregação) podemos perceber o impacto que a atratividade exerce sobre a qualidade da reconstrução de ambos os processos  $\Psi_{4V}$  e  $\Psi_{4K}$ . Ilustramos isto através das figuras 4.18 e 4.19.

A figura 4.18 ilustra a reconstrução por Voronoi  $\Psi_{4V}$  do fenômeno iluminação  $f$  a partir do conjunto de dados resultante da agregação realizada entre os sensores clusterizados através da técnica SKATER ( $\Psi_{3S}$ ).

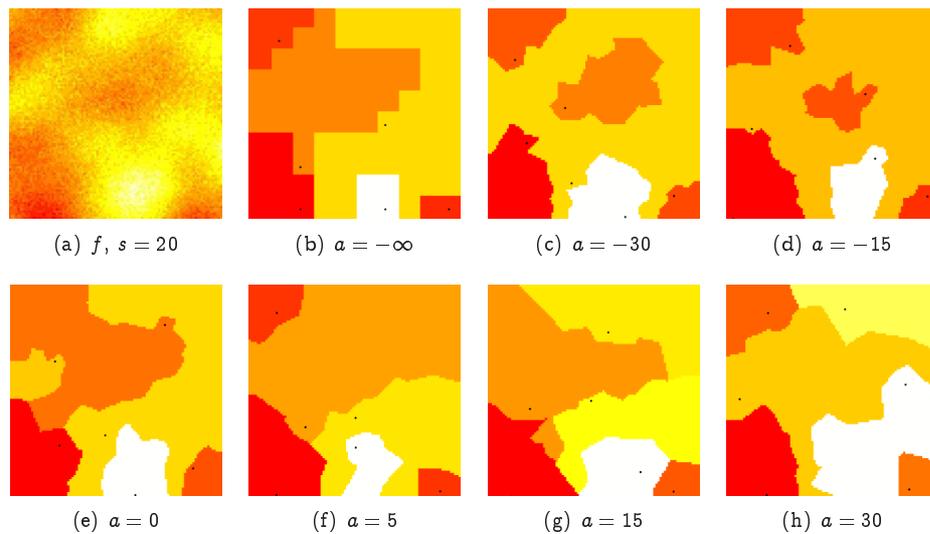


Figura 4.18: Reconstruções  $\Psi_{4V}$  a partir de  $\Psi_{3S}$  - 100 sensores na *situação 1*

Na figura 4.19 ilustramos a reconstrução por Kringing  $\Psi_{4K}$  do fenômeno iluminação  $f$  a partir  $\Psi_{3S}$ .

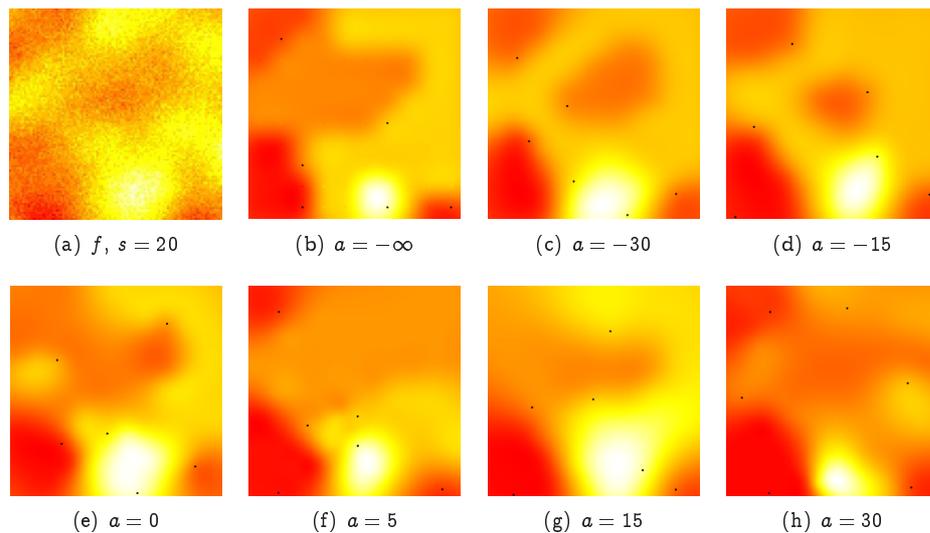


Figura 4.19: Reconstruções  $\Psi_{4K}$  a partir de  $\Psi_{3S}$  - 100 sensores na *situação 1*

E por fim, ilustramos nas figuras 4.20 e 4.21 a reconstrução por Voronoi e por Kringing, respectivamente, a partir da agregação dos dados de amostragem dos sensores clusterizados pela técnica LEACH  $\Psi_{3L}$ . Pelas figuras podemos perceber o impacto causado, a ambos os processos de reconstrução, pela técnica LEACH ao desconsiderar a correlação entre os dados durante a formação dos *clusters*.

Na figura 4.20 ilustramos a reconstrução por Kringing  $\Psi_{4V}$  do fenômeno iluminação  $f$  a partir  $\Psi_{3L}$ .

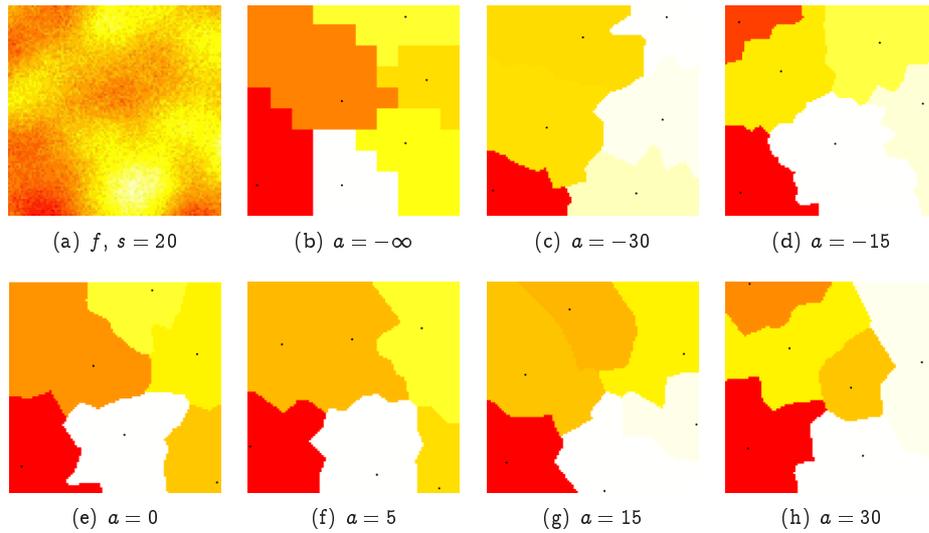


Figura 4.20: Reconstruções  $\Psi_{4V}$  a partir de  $\Psi_{3L}$  - 100 sensores na *situação1*

A figura 4.21 ilustra a reconstrução por Kriging  $\Psi_{4K}$  do fenômeno iluminação  $f$  a partir  $\Psi_{3L}$ .

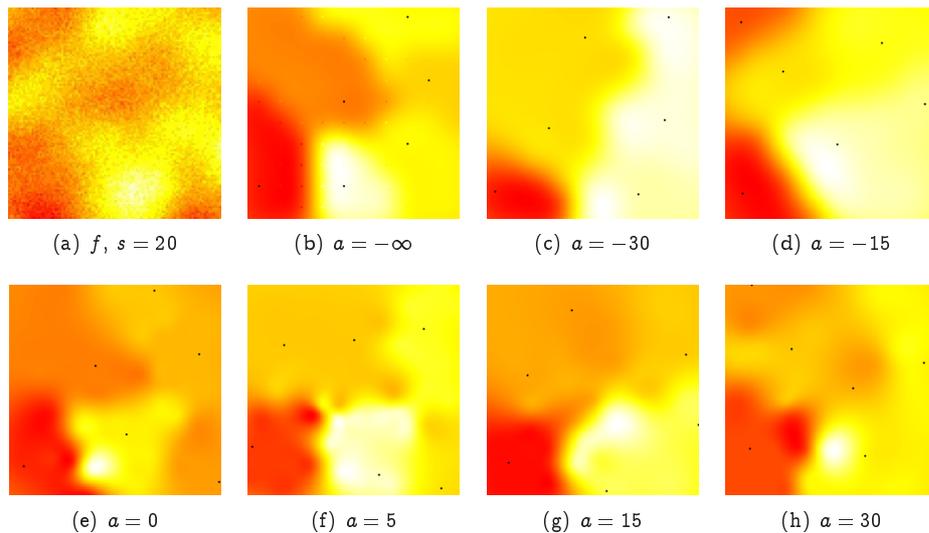


Figura 4.21: Reconstruções  $\Psi_{4K}$  a partir de  $\Psi_{3L}$  - 100 sensores na *situação1*

## 4.6 Resultados e Avaliações para a Situação2

Nesta seção mostramos algumas análises e resultados da reconstrução do fenômeno  $f$  que obtivemos ao empregar os processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  em nossas simulações para a *situação2*.

Com o intuito de uma maior aproximação da realidade, foram realizadas as simulações para a *situação2*, sob as mesmas condições definidas para a *situação1* (ver Seção 3.5).

A *situação2* difere da *situação1* apenas quanto ao modelo adotado para os sensores *tipo2*. As características de comunicação e percepção dos sensores *tipo2*, apresentadas na Seção 3.3.4, representam fatores que influenciam diretamente as operações (amostragem, clusterização e agregação) realizadas pela rede sensores que irão definir o resultado final do processo de reconstrução.

As operações de amostragem, clusterização e agregação realizadas pela rede de sensores na *situação2* foram modeladas nas seções 3.3.5.2 (página 25), 3.3.6.2 (página 28) e 3.3.7 (página 29), respectivamente.

Um sensor *tipo1*, modelado na *situação1*, pode comunicar-se diretamente com todos os sensores que ele compartilha pelo menos um vértice da sua célula de Voronoi. Desta forma, a figura 4.22(a) ilustra os vizinhos do sensor marcado na cor azul.

Na *situação2*, todos os sensores dentro do raio de comunicação  $r_c$  de um sensor *tipo2* são vizinhos deste sensor. Na figura 4.22(b) ilustramos o raio de comunicação  $r_c$  do sensor em azul e seus vizinhos (ver detalhes de implementação de  $r_c$  na Seção 3.6.3.6, página 43).

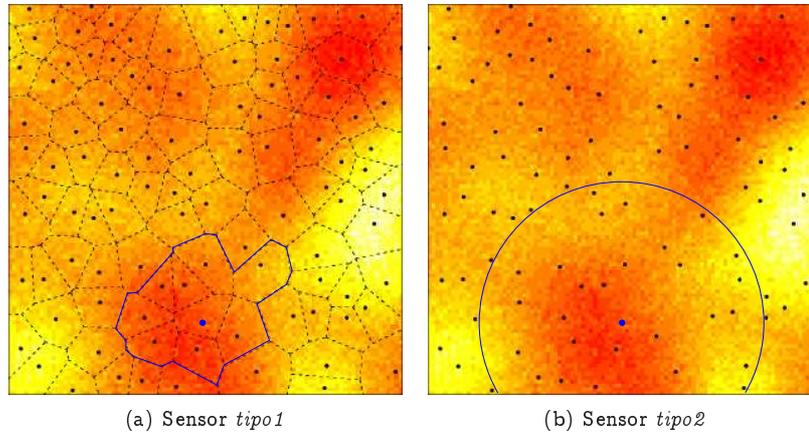


Figura 4.22: Características de comunicação dos sensores na *Situação1* e na *Situação2*

Na figura 4.23 ilustramos uma ocorrência de todo o processo sob estudo na *situação2*, considerando o processo pontual repulsivo  $a = -30$ .

A figura 4.23(a) ilustra o fenômeno  $f$  sob observação com escala  $s = 20$  e a figura 4.23(b) ilustra as área de percepção de cada sensor como sendo a área circular de raio fixo definida pela função de resposta radial dos sensores *tipo2*.

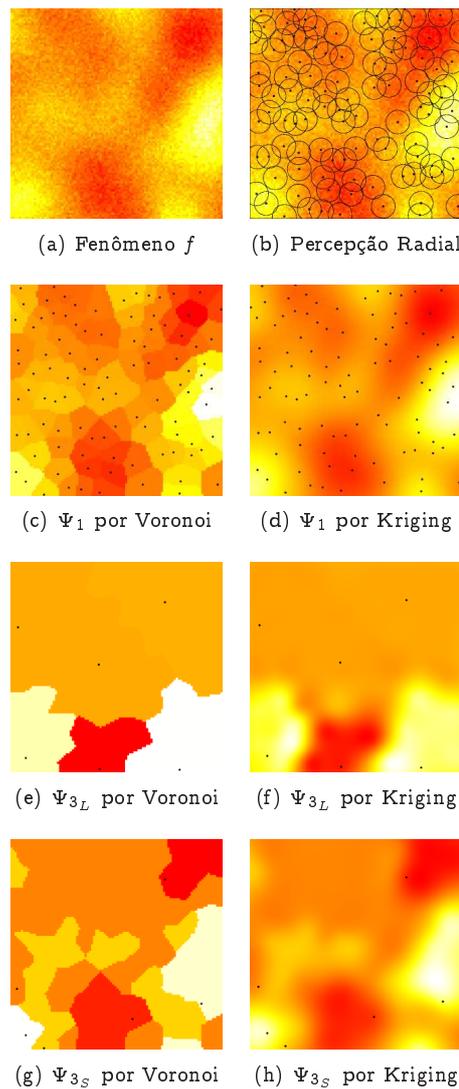


Figura 4.23: Reconstruções  $\Psi_4$  a partir de  $\Psi_1$ ,  $\Psi_{3L}$  e de  $\Psi_{3S}$  - 100 sensores na *situação2*

Percebemos pela figura 4.23(b) que na *situação2*, diferentemente do que ocorre na *situação1*, há áreas nas quais o fenômeno  $f$  não é percebido por nenhum dos sensores da rede. Além disto, na *situação2* as dimensões das áreas de percepção são fixas e iguais para todos os sensores da rede (ver consideração de implementação na Seção 3.6.3.4), fato que não ocorre na *situação1* visto que a área de percepção de cada sensor é definida como a célula de Voronoi a ele associada e suas dimensões variam de sensor para sensor.

As figuras 4.23(c), 4.23(e) e 4.23(g) ilustram a reconstrução de  $f$  resultante do processo de reconstrução por Voronoi  $\Psi_{4V}$  aplicado a partir dos conjuntos de dados: (i) amostragens individuais dos sensores ainda não clusterizados ( $\Psi_1$ ), (ii) agregação dos dados amostrados por sensores clusterizados pela técnica de LEACH ( $\Psi_{3L}$ ) e (iii) agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3S}$ ). Nas figuras 4.23(d), 4.23(f) e 4.23(h) ilustramos a reconstrução do fenômeno  $f$  ao aplicarmos o processo de reconstrução por Kriging  $\Psi_{4K}$  aos mesmos conjuntos de dados  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$ .

A seguir, considerando isoladamente a *situação2* e com base nas medidas de avaliação definidas na Seção 4.3, apresentamos algumas avaliações, descritas na tabela 4.2, dos estimadores média e variância dos erros de reconstrução do fenômeno  $f$  resultante do emprego dos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  para cada uma das 100 replicações das possíveis combinações entre os processos pontuais  $a \in \{-\infty, -30, -15, 0, 5, 15, 30\}$  e as escalas  $s = \{5, 10, 15, 20\}$  (ver definição do estudo Monte Carlo na Seção 3.5, página 40).

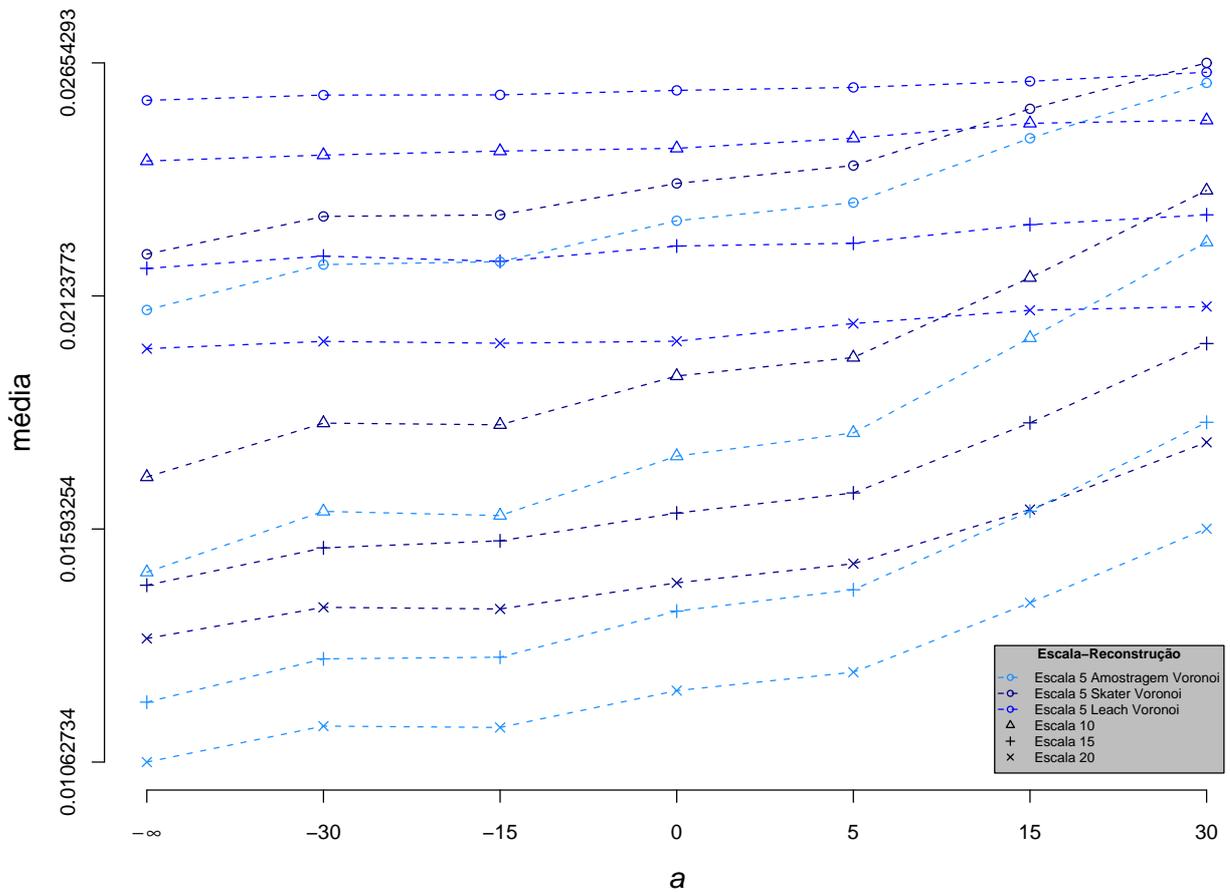


Figura 4.24: Média do erro de Reconstrução por Voronoi a partir de  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$  - Situação2

A figura 4.24 ilustra a reconstrução por Voronoi  $\Psi_{4V}$  do fenômeno  $f$  a partir de  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$  para a situação2.

Da mesma forma que na situação1, o erro de reconstrução é crescente na seguinte ordem: amostragem  $\Psi_1$ , SKATER  $\Psi_{3S}$  e LEACH  $\Psi_{3L}$ . As diferenças são estatisticamente significativas ao nível 99%.

Diferentemente do que ocorre com o erro de reconstrução a partir de  $\Psi_{3L}$ , os erros de reconstrução por Voronoi a partir de  $\Psi_1$  e  $\Psi_{3S}$  apresentam, para todas as escalas  $s$ , uma tendência de crescimento à medida que o processo pontual  $a$  se torna mais atrativo. No entanto, pelo intervalo de confiança de 99%, não podemos dizer que as medidas para os processo pontuais  $a = \{-30, -15\}$  nas escalas  $s = \{10, 15, 20\}$  diferem significativamente.

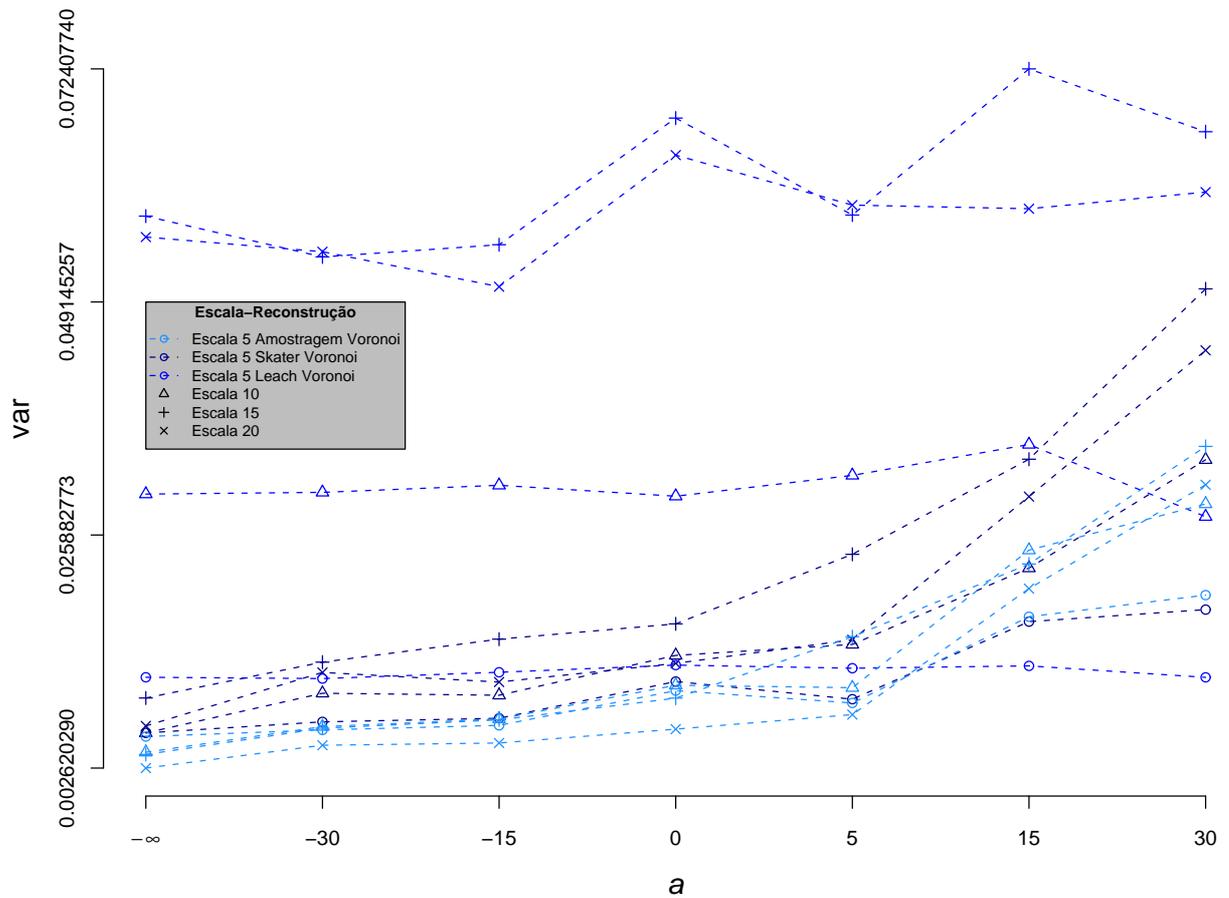


Figura 4.25: Variância do erro de Reconstrução por Voronoi a partir de  $\Psi_1$ ,  $\Psi_{3L}$  e  $\Psi_{3S}$  - Situação2

Na figura 4.25 percebemos que as maiores variâncias do erro de reconstrução por Voronoi  $\Psi_{4V}$  ocorreram para o LEACH  $\Psi_{3L}$  nas maiores escalas  $s = \{15, 20\}$  com todos os processos pontuais e na escala  $s = 10$  nos processos pontuais  $a = \{-\infty, -30, -15, 0, 5\}$ . Para a menor escala  $s = 5$ , já não são tão significativas as diferenças entre a variância do erro a partir de LEACH e as variâncias dos erros a partir da amostragem e do SKATER, inclusive passando estas últimas a apresentar maior variância que  $\Psi_{3L}$  para os processos pontuais  $a = \{15, 30\}$ .

Observamos, também, que os erros de reconstrução por Voronoi a partir de  $\Psi_1$  e de  $\Psi_{3S}$ , para todas as escalas, apresentaram aumento mais acentuado da variância para os processos atrativos  $a = \{15, 30\}$ .

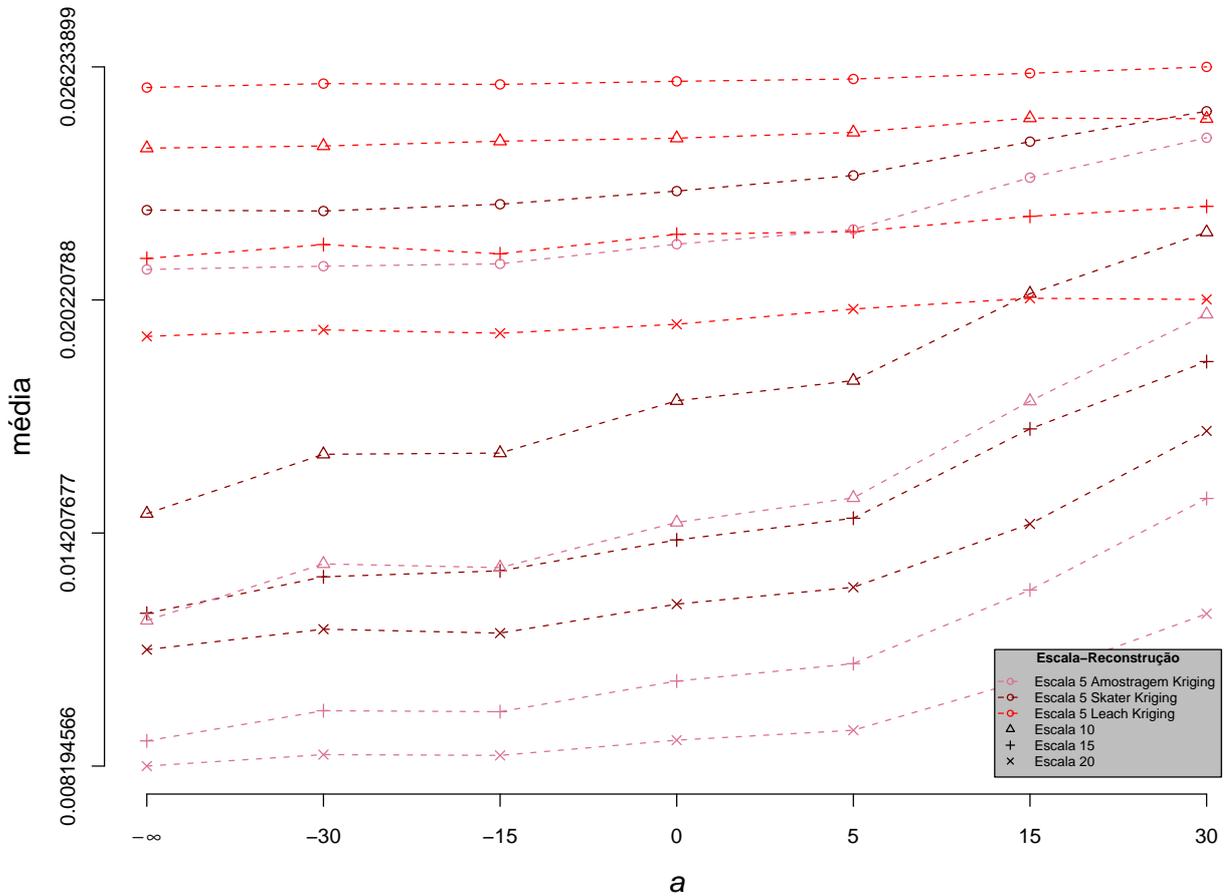


Figura 4.26: Média do erro de Reconstrução por Kriging a partir de  $\Psi_1$ ,  $\Psi_{3_L}$  e  $\Psi_{3_S}$  - *Situação2*

Considerando o processo de reconstrução por Kriging  $\Psi_{4_K}$  na *situação2* podemos, a partir da figura 4.26, extrair conclusões semelhantes as obtidas a partir da figura 4.24 relativa ao processo de reconstrução por Voronoi para a *situação2*.

Para todos os processo pontuais  $a = \{-\infty, -30, -15, 0, 5, 15, 30\}$  e todas as escalas  $s = \{5, 10, 15, 20\}$ , o erro de reconstrução de fenômeno  $f$  é crescente ao aplicarmos o processo de reconstrução por Kriging  $\Psi_{4_K}$  aos três conjuntos de dados na seguinte ordem:  $\Psi_1$ ,  $\Psi_{3_S}$  e  $\Psi_{3_L}$ . Pelo intervalo de confiança de 99%, podemos afirmar que as médias diferem significativamente, exceto ao compararmos  $\Psi_1$  e  $\Psi_{3_S}$ , para o processo pontual  $a = 30$  com escala  $s = 5$ .

O erro de reconstrução por Kriging a partir de amostragem  $\Psi_1$  e do SKATER  $\Psi_{3_S}$ , para todas as escalas, cresce à medida que o processo pontual se torna mais atrativo. No entanto, pelo intervalo de confiança de 99%, não podemos dizer que as medidas para os processo pontuais  $a = \{-30, -15\}$  nas escalas  $s = \{10, 15, 20\}$  diferem significativamente.

Quanto ao erro de reconstrução a partir do LEACH  $\Psi_{3_L}$ , já não podemos afirmar que o erro cresce com a atratividade nas escalas. Da mesma forma como observamos na *situação1*, isto ocorre com o LEACH na *situação2* um vez que ele não considera a correlação entre os dados.

Para todos os conjuntos de dados  $\Psi_1$ ,  $\Psi_{3_S}$  e  $\Psi_{3_L}$ , o erro de reconstrução de  $f$  resultante do processo de reconstrução por Kriging  $\Psi_{4_K}$  cresce com a granularidade dos dados. Isto ocorre pois quanto maior a granularidade dos dados em  $f$  maior a dificuldade imposta à estimação realizada pela técnica Kriging. Em nossas simulações aumentamos a granularidade dos dados em  $f$  ao diminuir o parâmetro escala  $s$  (ver nossa modelagem para o fenômeno em observação na Seção 3.3.2, página 17).

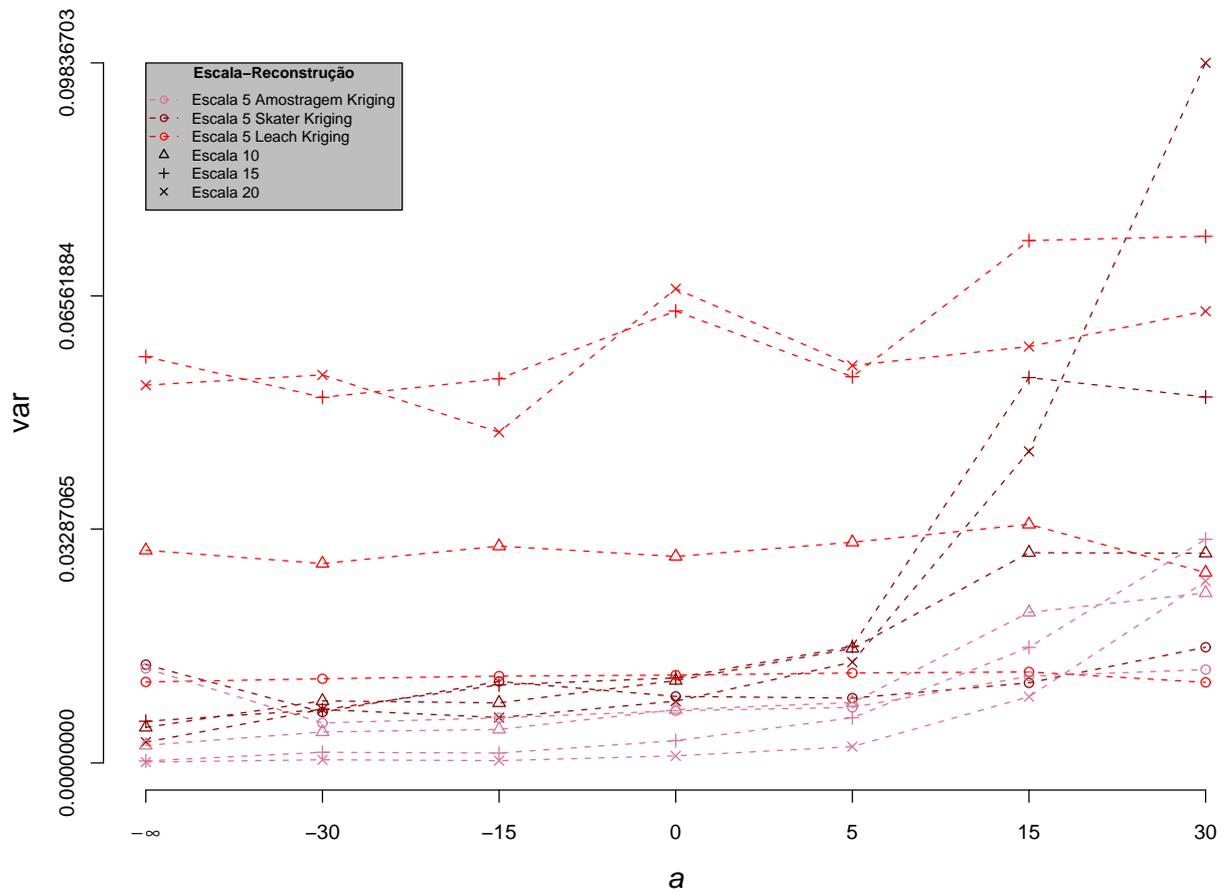


Figura 4.27: Variância do erro de Reconstrução por Kriging a partir de  $\Psi_1$ ,  $\Psi_{3_L}$  e  $\Psi_{3_S}$  - Situação2

Pela figura 4.27 observamos uma menor variância do erro de reconstrução por Kriging  $\Psi_{4_K}$  a partir da amostragem  $\Psi_1$  para as escalas maiores  $s = \{15, 20\}$  com os processos pontuais  $a = \{-\infty, -30, -15, 0, 5\}$ , ocorrendo um aumento dessa variância para os processo pontuais mais atrativos  $a = \{15, 30\}$ .

Observamos por esta figura que o processo de reconstrução por Kriging  $\Psi_{4_K}$  para o SKATER  $\Psi_{3_S}$  apresenta, a partir do processo pontual atrativo  $a = 5$  e considerando as escalas  $s = \{15, 20\}$ , aumentos da variância à medida que o processo se torna mais atrativo.

Considerando as escalas  $s = \{10, 15, 20\}$ , e ao ser comparada com  $\Psi_1$  e com  $\Psi_{3_S}$ , a reconstrução a partir do LEACH  $\Psi_{3_L}$  apresenta no geral as maiores variâncias do erro, não se confirmando isto apenas quando comparada ao  $\Psi_{3_S}$  no processo pontual  $a = 30$  com a escala  $s = 20$ . Isto se deve à falta de homogeneidade entre valores de amostragem dos sensores membros dos *clusters* formados pelo LEACH.

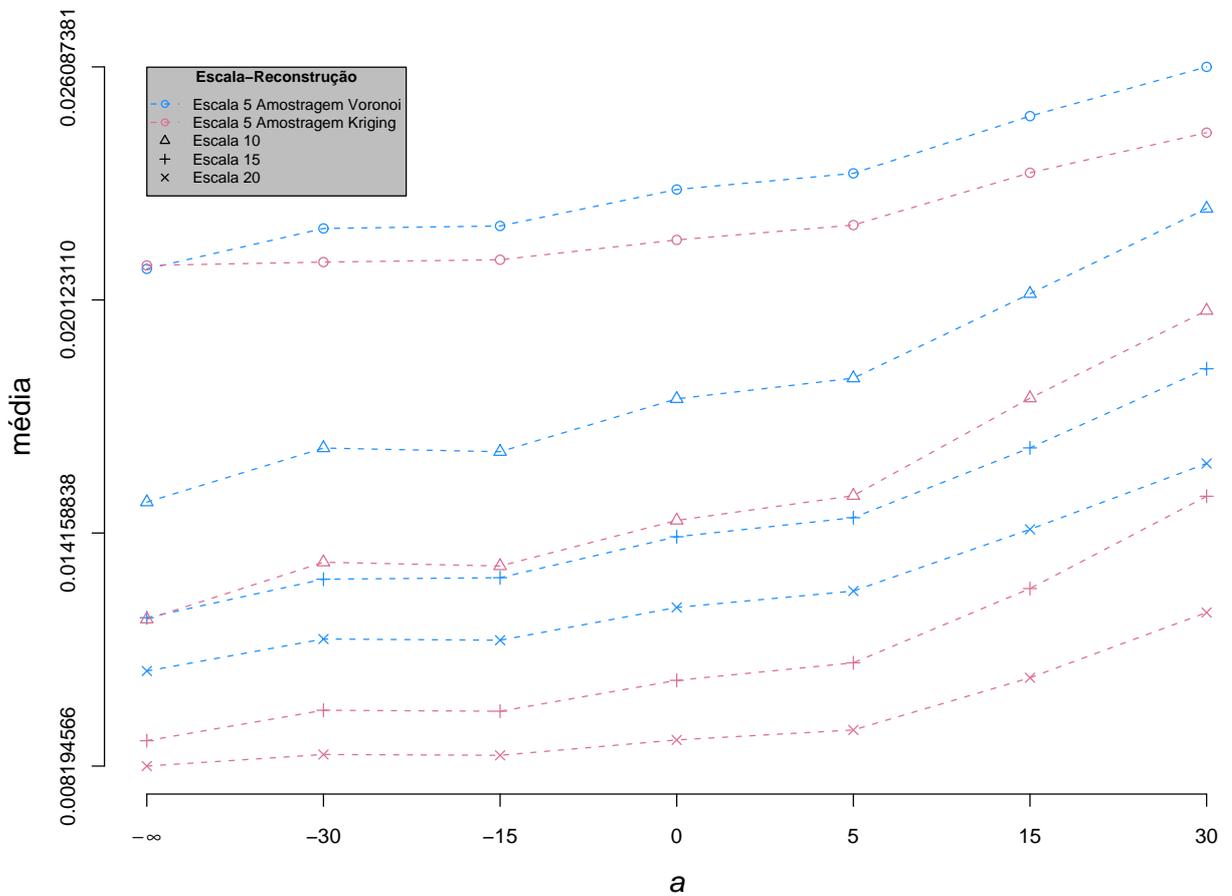


Figura 4.28: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_1$  - Situação2

A figura 4.28 compara a qualidade das reconstruções obtidas pelos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  quando aplicados a partir dos dados de amostragem individual dos sensores  $\Psi_1$ .

Pela figura 4.28 percebemos que na *situação2* ambos os processos perdem qualidade na reconstrução a medida que o processo pontual se torna mais atrativo. Uma consequência direta da atratividade é o aumento das áreas sem cobertura de percepção impactando numa menor qualidade de reconstrução do fenômeno sob observação.

Além da atratividade, quanto maior a granularidade ( $\epsilon$ , com isso, menor a escala  $s$ ) do fenômeno sendo amostrado e reconstruído maior é o erro de reconstrução de ambos os processos de reconstrução, independentemente do processo pontual.

Comparando os desempenhos dos dois processos de reconstrução  $\Psi_{4V}$  e  $\Psi_{4K}$ , concluímos que a reconstrução por Kriging do fenômeno  $f$  a partir dos dados de amostragem individual dos sensores apresenta melhores resultados ou qualidade que a mesma reconstrução por Voronoi  $\Psi_{4V}$  para todos os processos pontuais  $a$  e todas as escalas  $s$ , excetuando-se o caso  $a = \infty$  com escala  $s = 5$ . Neste último caso, as diferenças não se revelam significativamente diferentes ao nível 99%.

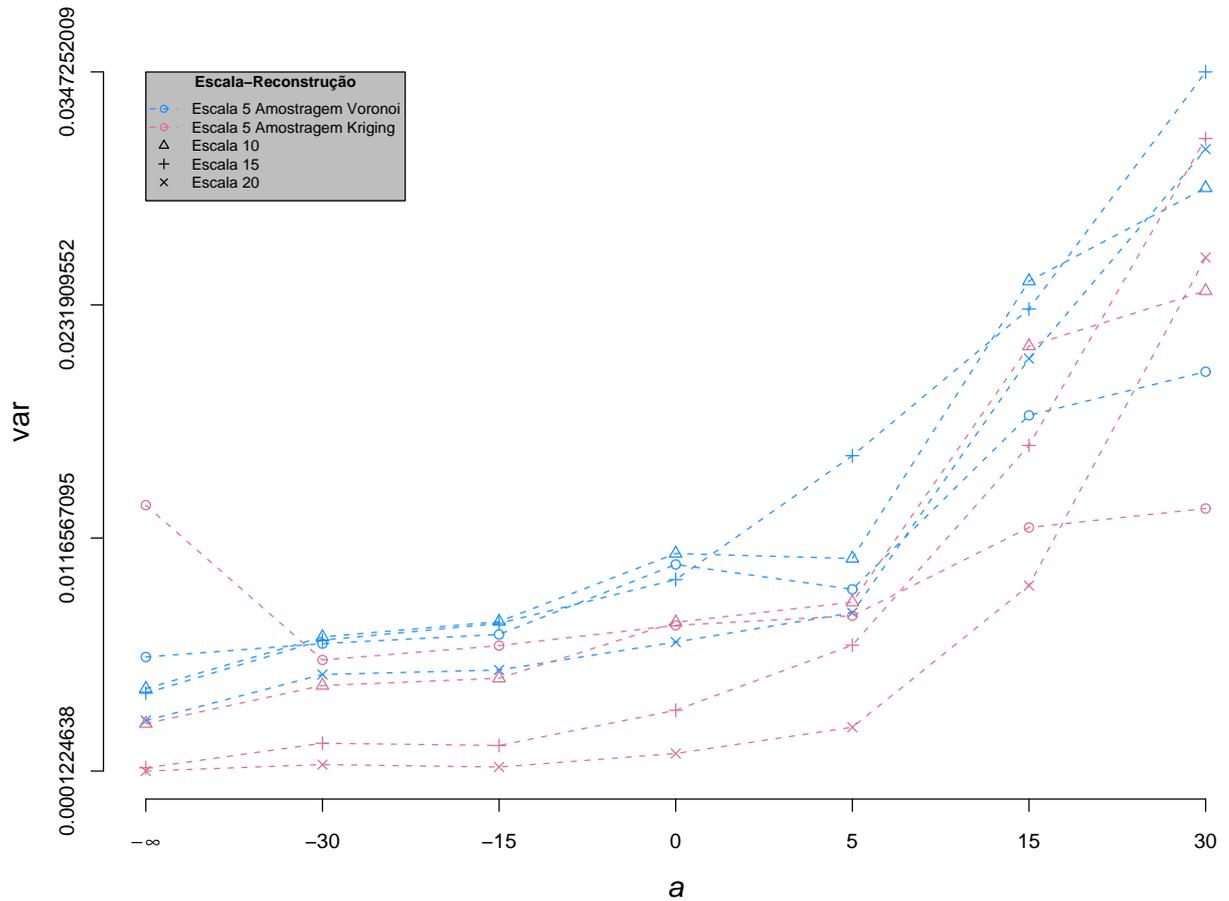


Figura 4.29: Variância do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_1$  - Situação2

A figura 4.29 ilustra a variância do erro de reconstrução do fenômeno  $f$  dos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  aplicados a partir dos dados de amostragem individual dos sensores  $\Psi_1$ .

Percebemos que a variância do erro de reconstrução resultante do processo  $\Psi_{4K}$  é menor que a variância do erro de reconstrução por Voronoi para todos os processos pontuais  $a$  e para todas as escalas  $s$  excetuando-se para  $a = -\infty$  com  $s = 5$ , e que para ambos os processos de reconstrução a variância é crescente com a atratividade.

Assim como constatamos na figura 4.28 referente à avaliação da média do erro de reconstrução por Voronoi e por Kriging a partir de  $\Psi_1$ , percebemos nesta avaliação que a variância do erro de reconstrução para o processo pontual  $a = -\infty$  com a escala  $s = 5$  representa o único caso no qual a variância do erro de reconstrução por Kriging é maior que a variância do erro de reconstrução por Voronoi.

Na figura 4.30 ilustramos a reconstrução do fenômeno  $f$  com escala  $s = 20$  pelos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  aplicados a partir de  $\Psi_1$  para os processos pontuais  $a = \{-\infty, -30, 30\}$ . Percebemos que ambos os processos perdem, com a atratividade, qualidade na reconstrução. Além disto, comparando 4.30(b) com 4.30(e), 4.30(c) com 4.30(f) e 4.30(d) com 4.30(g), constatamos uma melhor desempenho na reconstrução por Kriging.

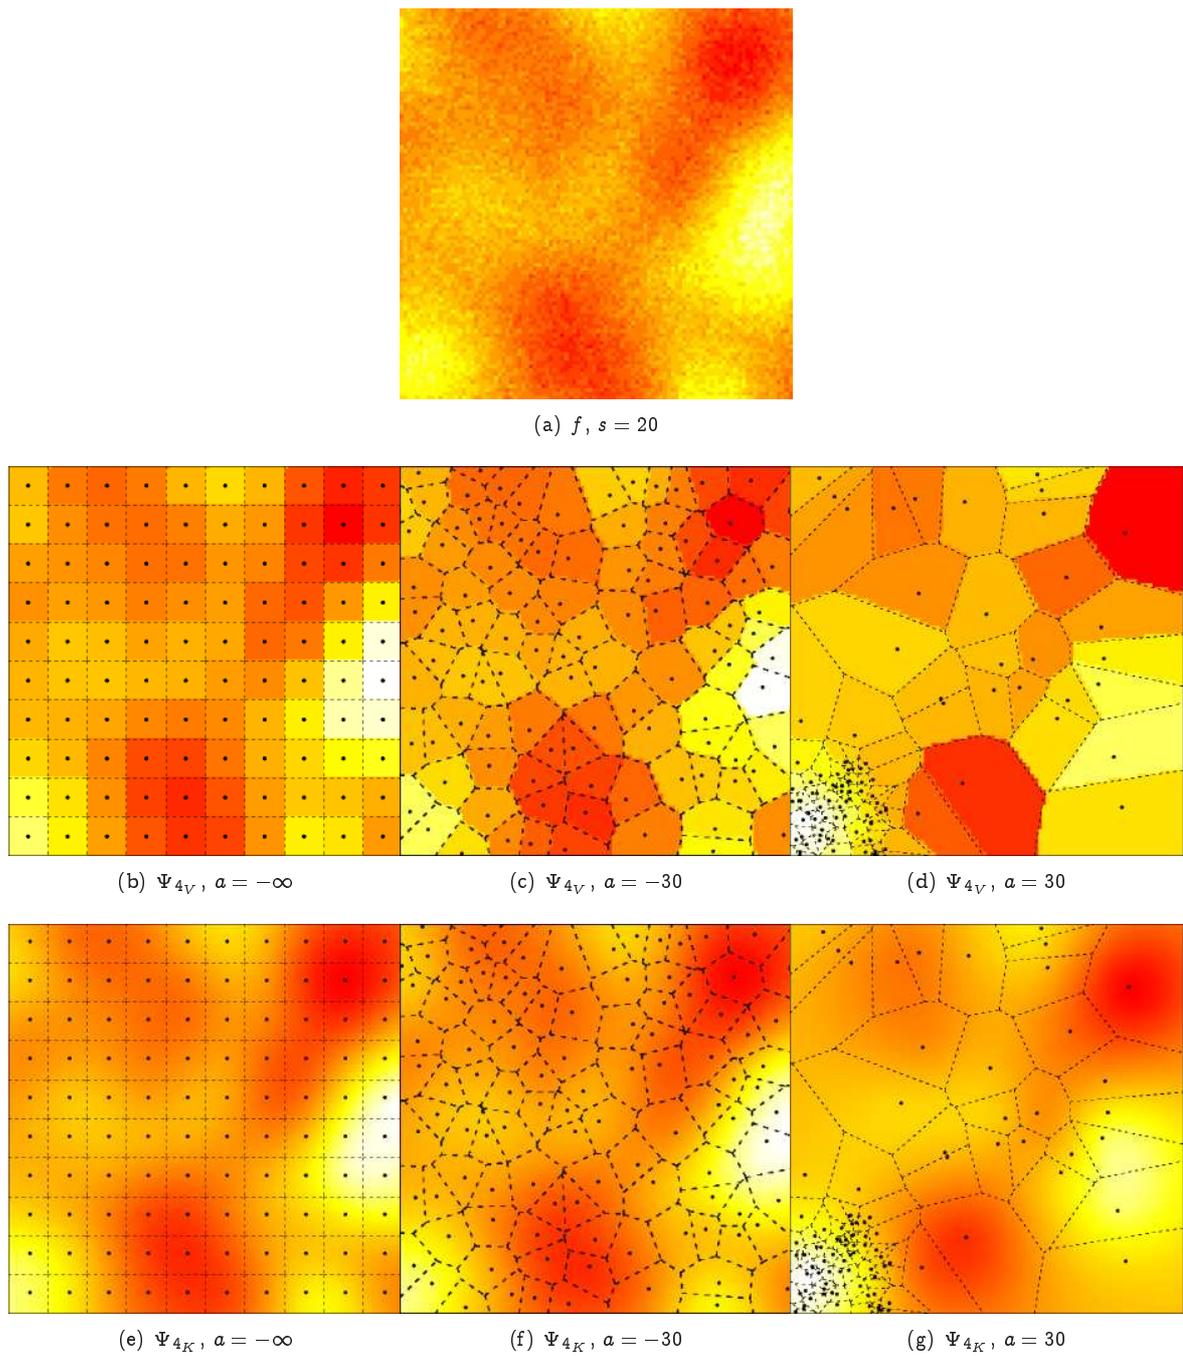


Figura 4.30: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_1$  na escala  $s = 20$  Situação2

Na figura 4.31 ilustramos a reconstrução, por Voronoi e por Kriging, do fenômeno  $f$  com escala  $s = 5$  para os processos pontuais  $a = \{-\infty, -30, 30\}$ . Analisando esta figura conjuntamente com a figura 4.30, percebemos que a medida que a granularidade do fenômeno  $f$  aumenta, menor é a qualidade obtida pelos processos de reconstrução  $\Psi_{4V}$  e  $\Psi_{4K}$  face à maior dificuldade imposta às tarefas de estimação realizadas na amostragem e na reconstrução.

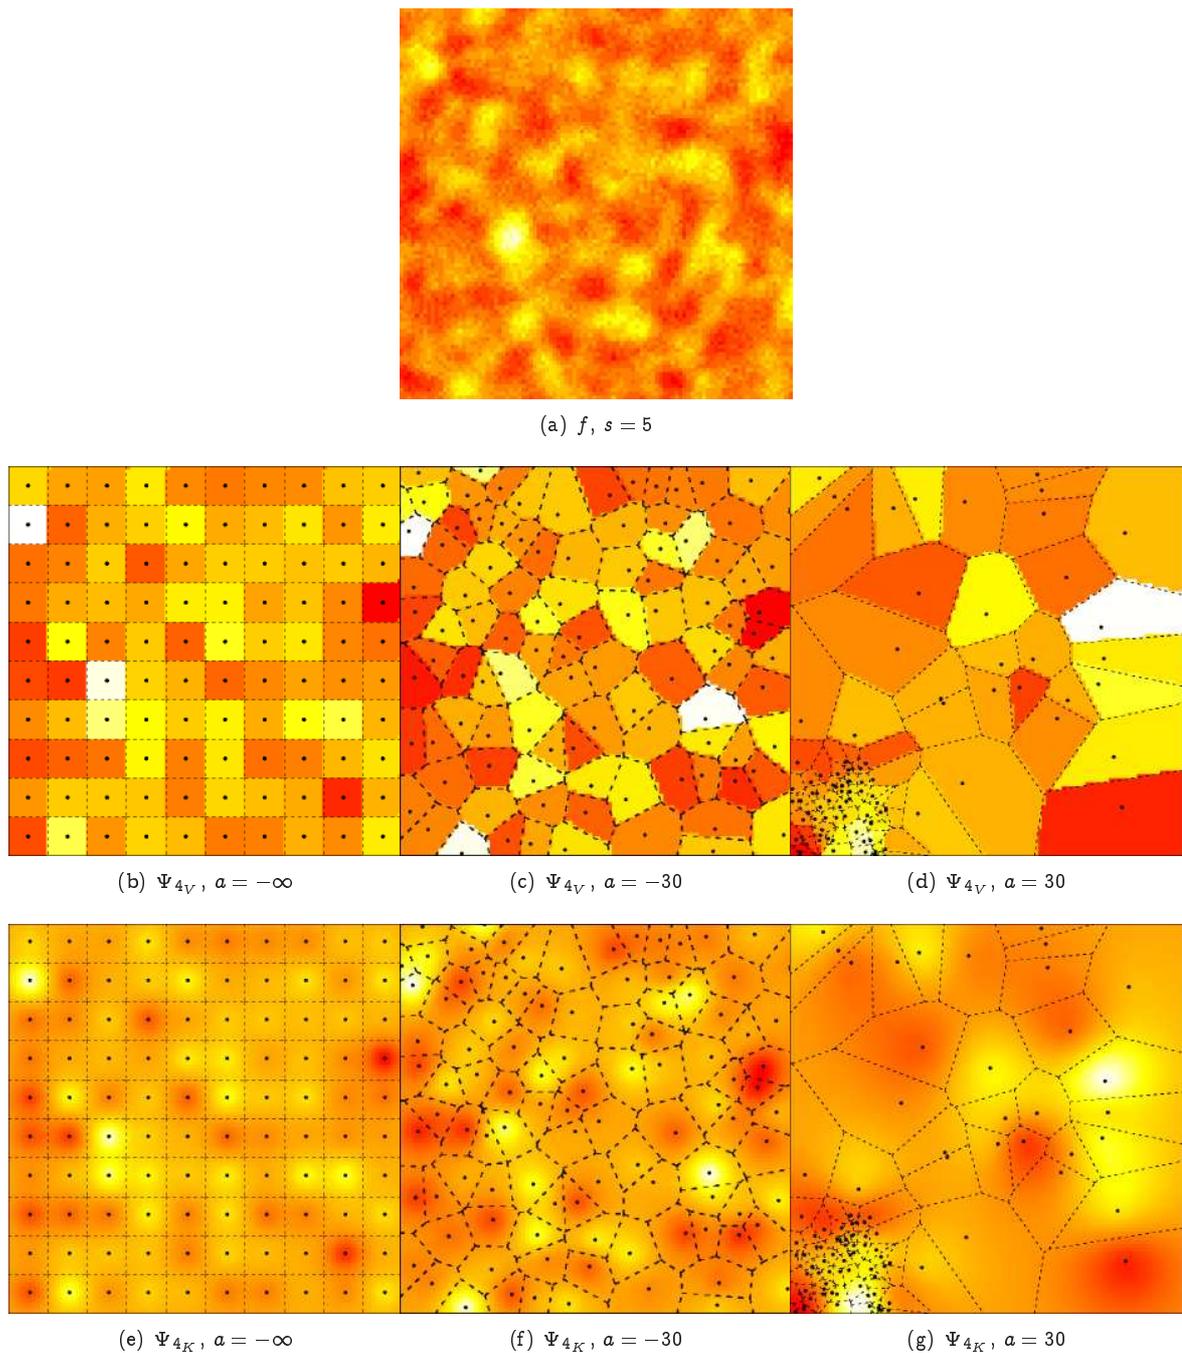


Figura 4.31: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_1$  na escala  $s = 5$  Situação2

As figuras 4.31(b) e 4.31(e) ilustram a comparação entre Voronoi e Kriging para o caso do processo pontual regular  $a = -\infty$  com escala  $s = 5$ , mostrando a dificuldade em estabelecermos qual dos processos de reconstrução obteve o melhor resultado na reconstrução de  $f$ . Para os demais casos, conforme a figura 4.30, a reconstrução por  $\Psi_{4K}$  obteve melhores resultados que  $\Psi_{4V}$ .

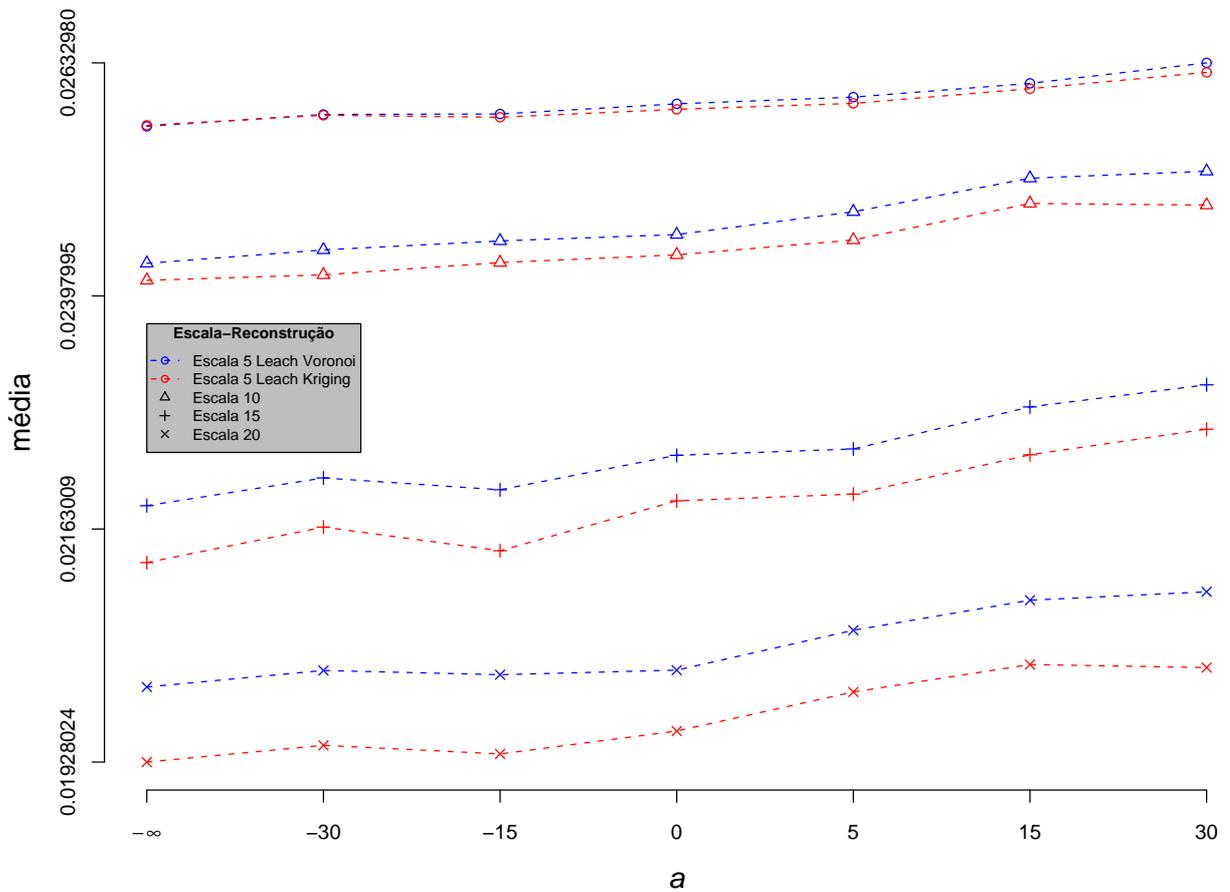


Figura 4.32: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3L}$  - Situação2

A figura 4.32 compara os desempenhos dos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  no tocante à qualidade da reconstrução do fenômeno iluminação  $f$  quando aplicados aos dados resultantes das operações de agregação e clusterização pela técnica LEACH ( $\Psi_{3L}$ ).

Percebemos que ambos os processos de reconstrução apresentam menores erros à medida que a escala  $s$  aumenta, independentemente do processo pontual  $a$ .

Embora pela figura poderíamos concluir que a reconstrução por Kriging obtém melhores resultados que a reconstrução por Voronoi para as escalas  $s = \{10, 15, 20\}$  para todos os processo, pelo intervalo de confiança de 95%, não podemos afirmar que essas medidas diferem significativamente.

Da mesma forma, independentemente da escala  $s$  sendo avaliada, não podemos dizer que o erro dos processos de reconstrução por  $\Psi_{4V}$  e por  $\Psi_{4K}$  cresce com a atratividade. Este comportamento decorre do fato de o LEACH não levar em consideração a correlação entre os dados durante a construção dos *clusters*.

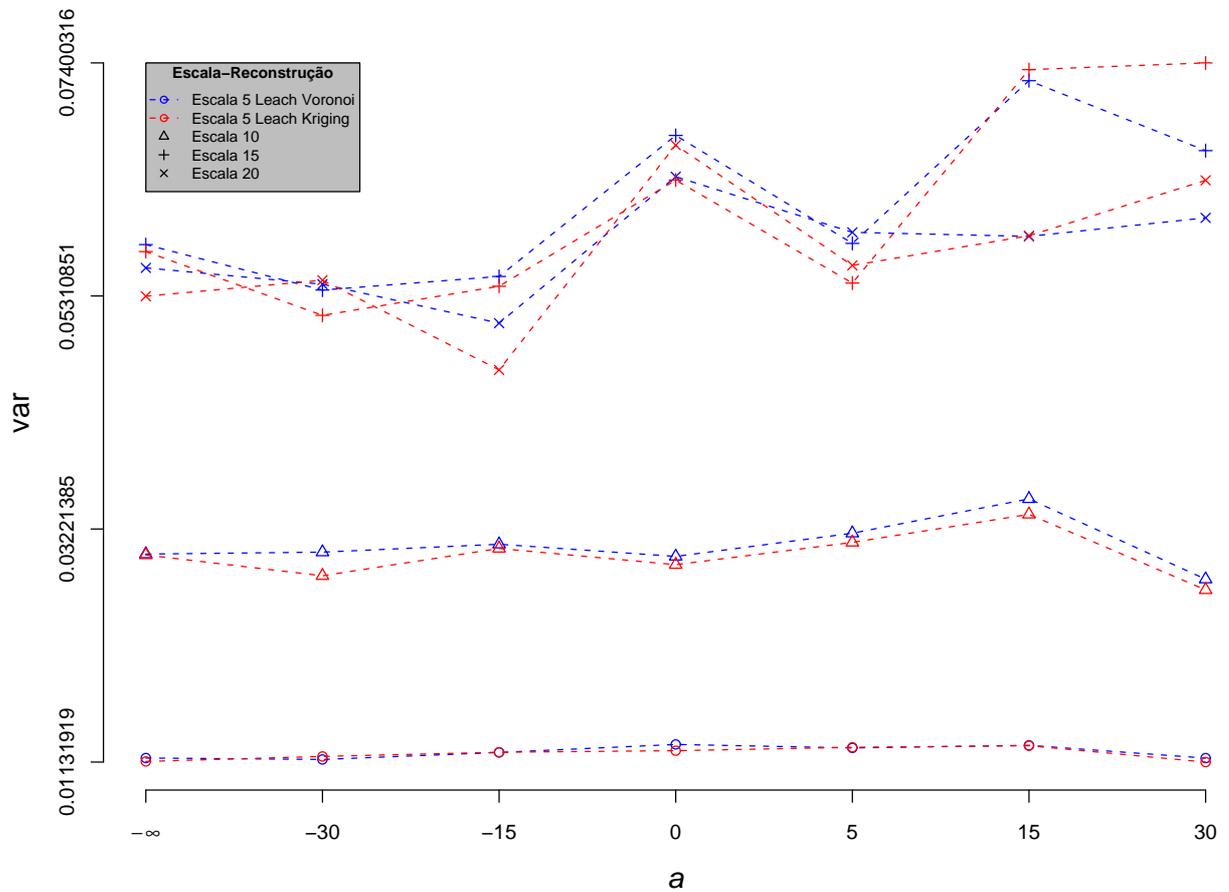


Figura 4.33: Variância do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3L}$  - Situação2

Embora pela figura 4.32 constatamos que os erros de reconstrução obtidos por ambos os processos de reconstrução, Voronoi  $\Psi_{4V}$  e Kriging  $\Psi_{4K}$ , apresentem-se menores para as maiores escalas  $s = \{15, 20\}$ , pela figura 4.33 percebemos, para estas mesmas escalas, as maiores variâncias do erro de reconstrução.

A figura 4.34 ilustra a reconstrução do fenômeno  $f$  com escala  $s = 20$  pelos processos de reconstrução  $\Psi_{4V}$  e  $\Psi_{4K}$  aplicados a partir de  $\Psi_{3L}$ , considerando os processos pontuais  $a = \{-\infty, -30, 30\}$ .

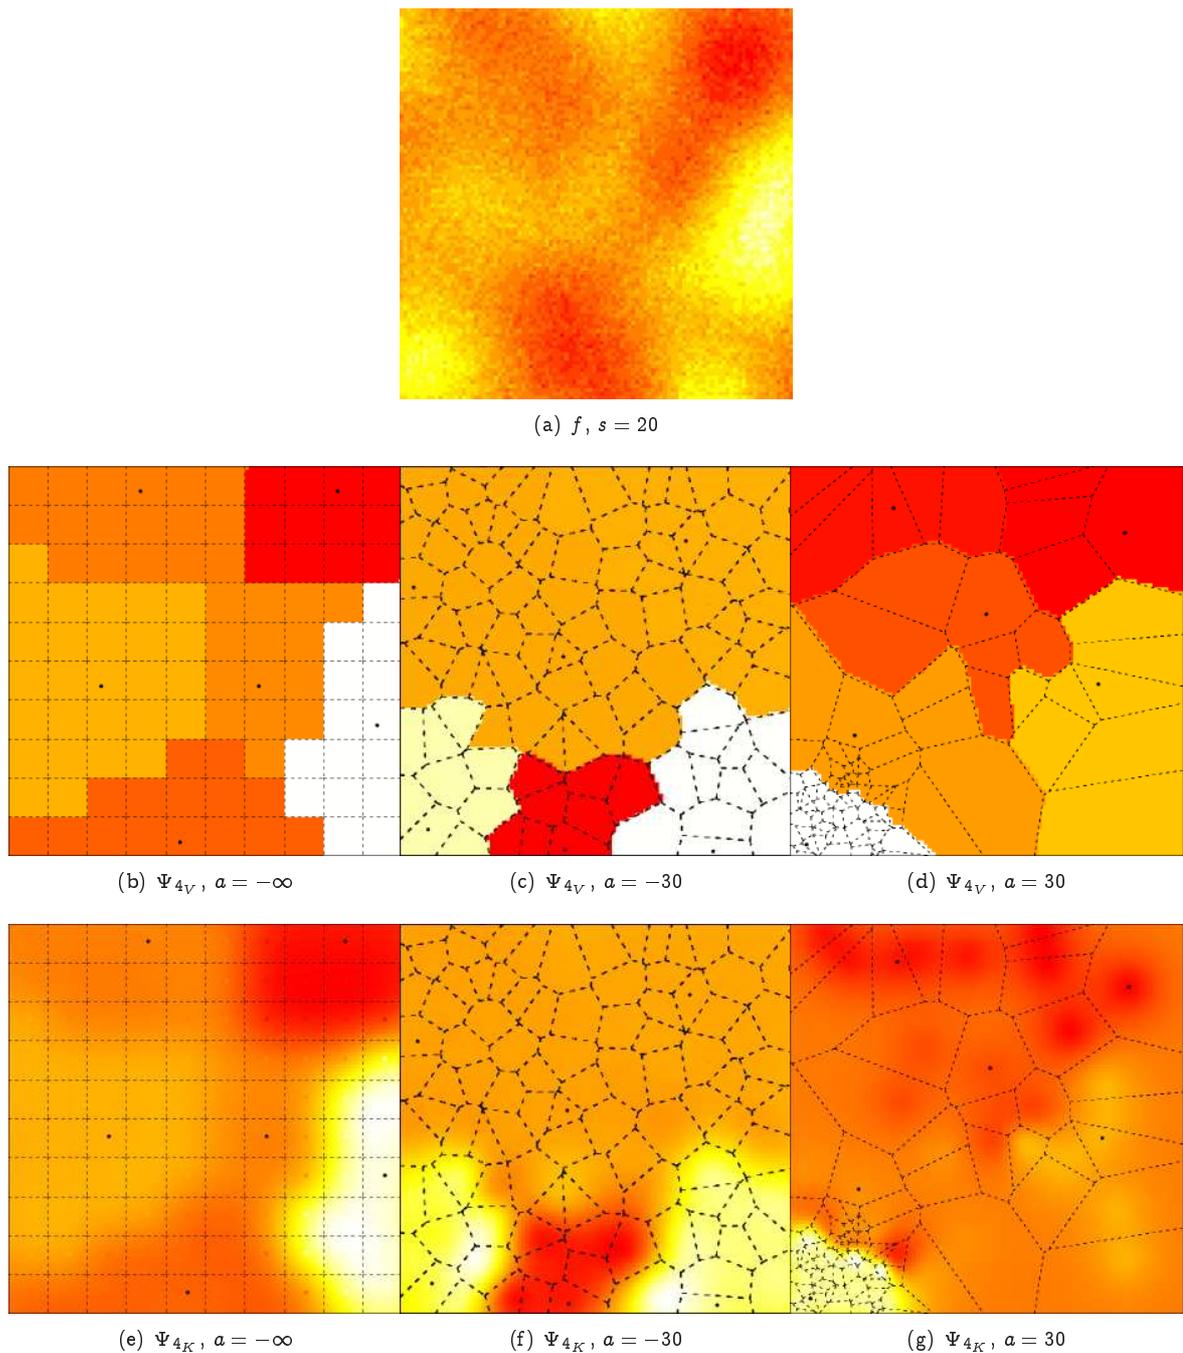


Figura 4.34: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_{3L}$  na escala  $s = 20$  Situação2

Reforçando nossas constatações quando da avaliação do erro de reconstrução a partir de  $\Psi_{3L}$  (na página 77), não podemos perceber o ganho ou a perda de qualidade com a atratividade nem tão pouco podemos posicionar qual dos dois processos reconstruiu melhor o fenômeno  $f$ , ainda que se perceba uma maior suavidade na reconstrução por Kriging quando comparada com a reconstrução por Voronoi.

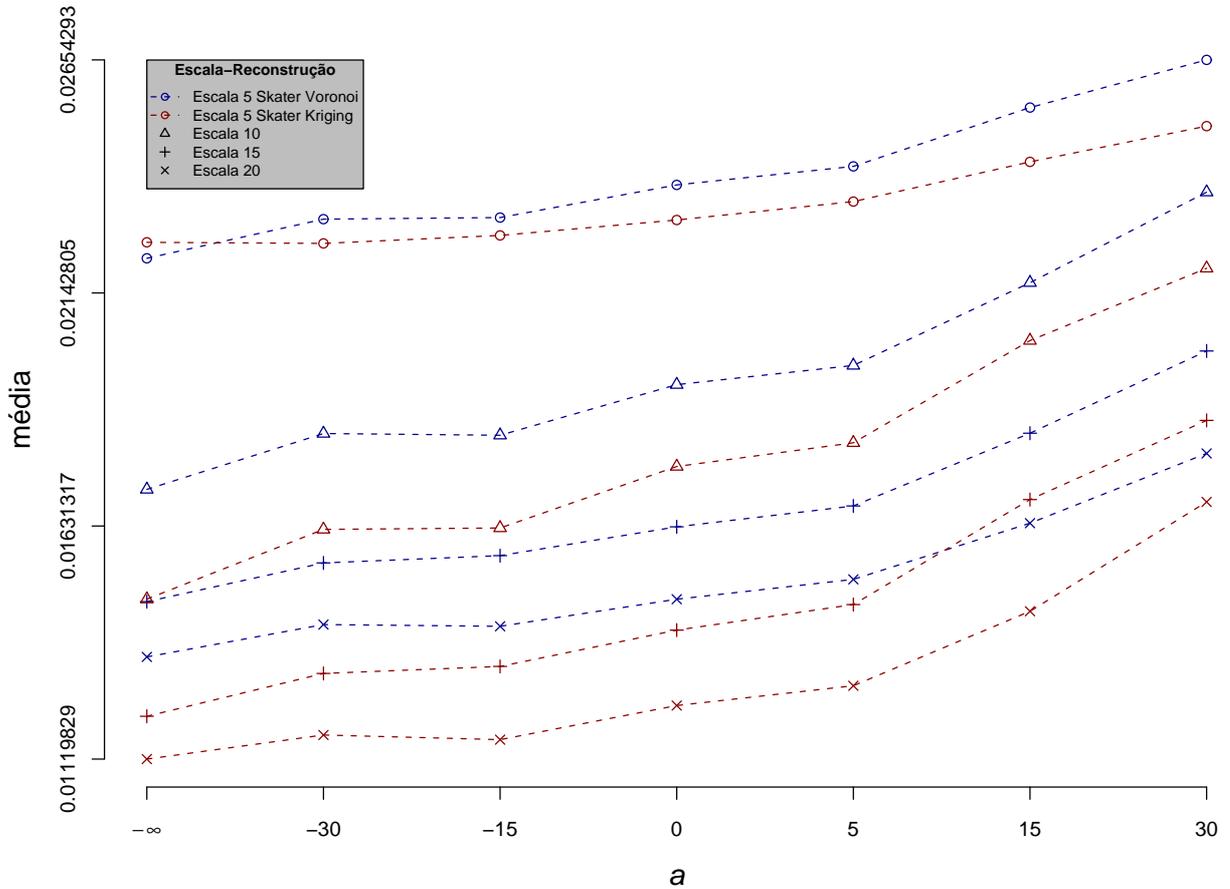


Figura 4.35: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3s}$  - Situação2

A figura 4.35 ilustra os erros de reconstrução obtidos pelos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  aplicados aos dados resultantes da agregação sobre os dados de amostragem dos sensores clusterizados através da técnica SKATER ( $\Psi_{3s}$ ).

Percebemos que o erro de reconstrução, para  $\Psi_{4V}$  e  $\Psi_{4K}$ , cresce com a atratividade em todas as escalas  $s$ .

Além disto, para ambos os processos de reconstrução e considerando todos os processos pontuais  $a$ , o erro de reconstrução cresce com a granularidade, ou seja, quanto menor a escala  $s$  pior a qualidade da reconstrução de  $f$ .

Comparando o desempenho entre os dois processos de reconstrução, constatamos que a reconstrução por Kriging obteve os melhores resultados para todos os processos pontuais  $a$  e todas as escalas  $s$ , com exceção para os casos  $a = -\infty$  com  $s = 5$ ,  $a = -15$  com  $s = 5$  e  $a = 30$  com  $s = 20$  onde, pelo intervalo de confiança de 99%, não podemos afirmar que as medidas diferem significativamente.

Na figura 4.36 ilustramos a reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3s}$  do fenômeno  $s$  com escala  $s = 20$  para os processos pontuais  $a = \{-\infty, -15, 30\}$ .

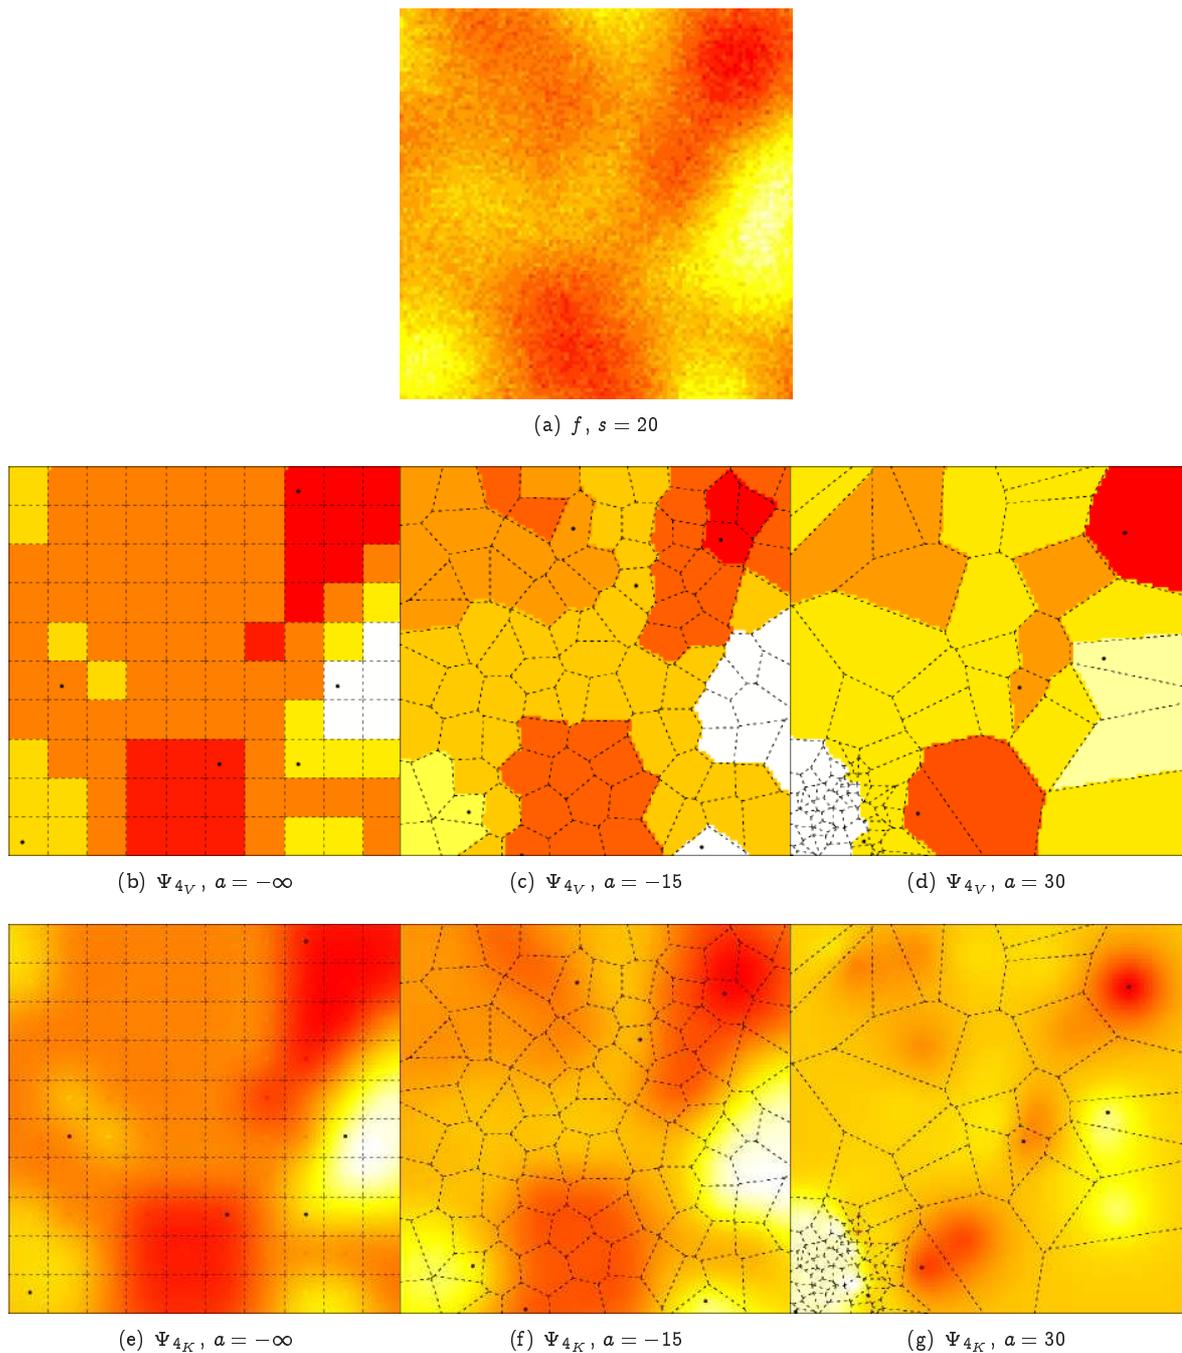


Figura 4.36: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_{3S}$  na escala  $s = 20$  Situação2

Percebe-se pelas figuras 4.36(b), 4.36(c) e 4.36(d) e pelas figuras 4.36(e), 4.36(f) e 4.36(g) que há uma perda na qualidade da reconstrução com o aumento da atratividade. Diferentemente das demais, não podemos perceber pelas figuras 4.36(d) e 4.36(g) qual dos dois processos reconstruiu melhor  $f$ . Isto reforça a constatação do impacto da atratividade, também verificado na *situação1*, sobre as operações de amostragem, clusterização e agregação realizada pela rede de sensores e, como conseqüência, nos resultados dos processos de reconstrução.

Apresentamos a figura 4.37 para ilustrar as dificuldades impostas pela granularidade do fenômeno  $f$  às operações de amostragem, clusterização, agregação e reconstrução. Pelas figuras 4.37(b) e 4.37(e) e pelo gráficos da figura 4.35 não podemos dizer qual dos dois processos  $\Psi_{4V}$  e  $\Psi_{4K}$  reconstruiu melhor  $f$  com escala  $s = 5$  (granularidade).

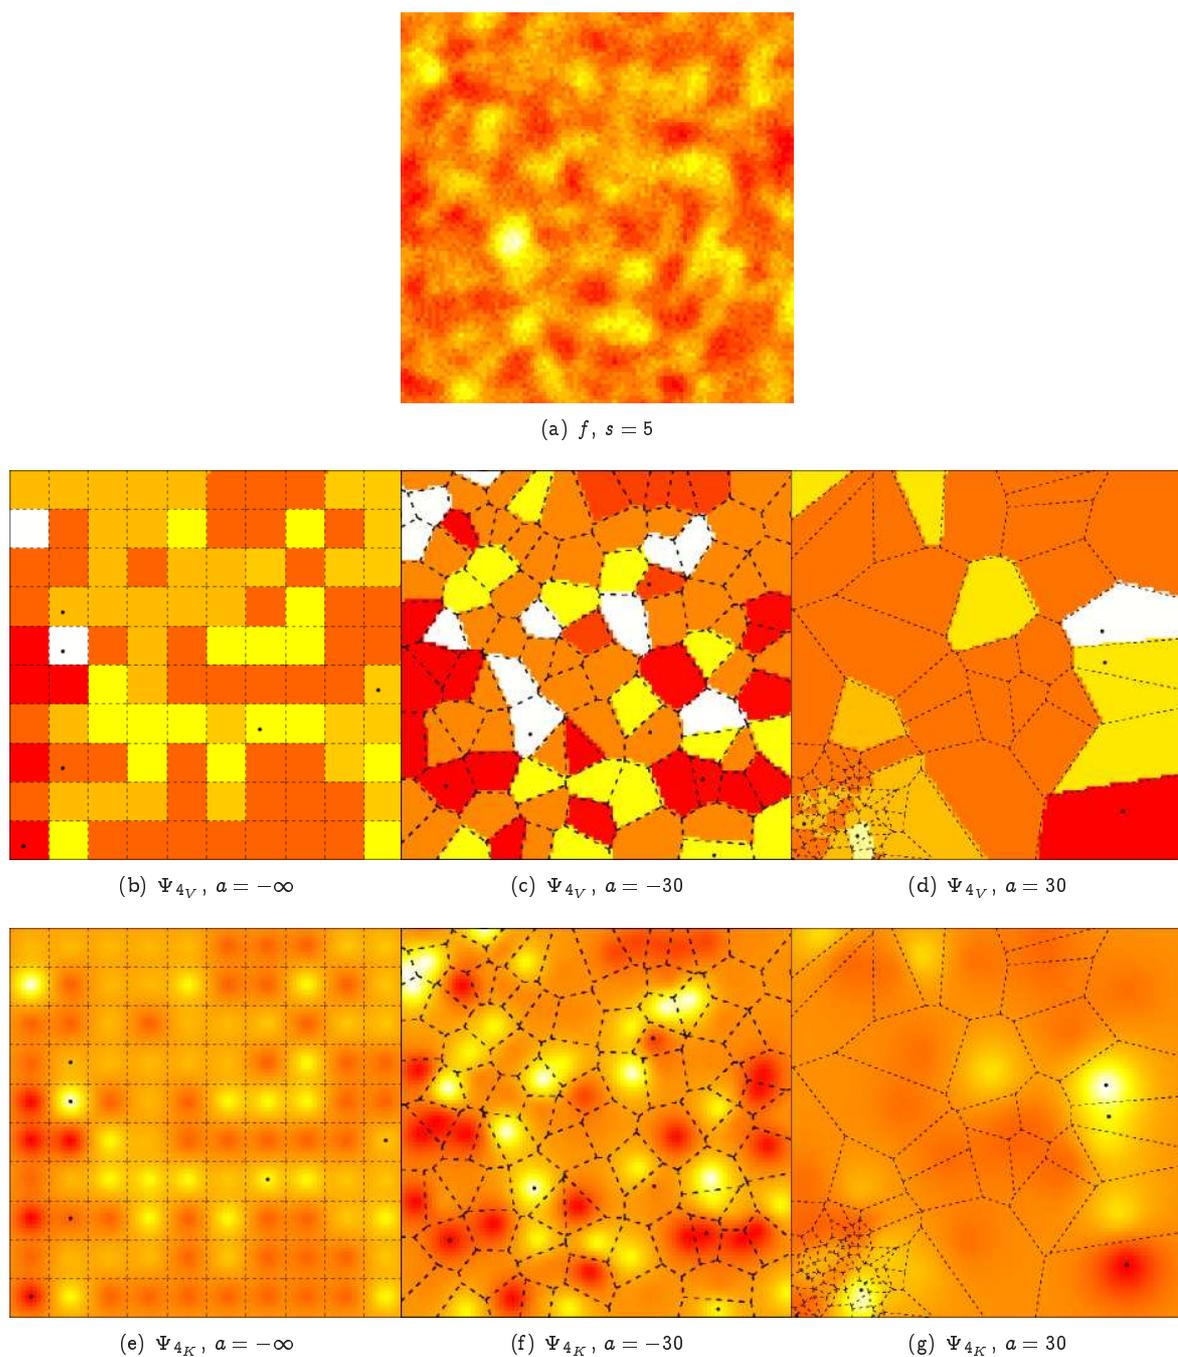


Figura 4.37: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_{3S}$  na escala  $s = 5$  Situação2

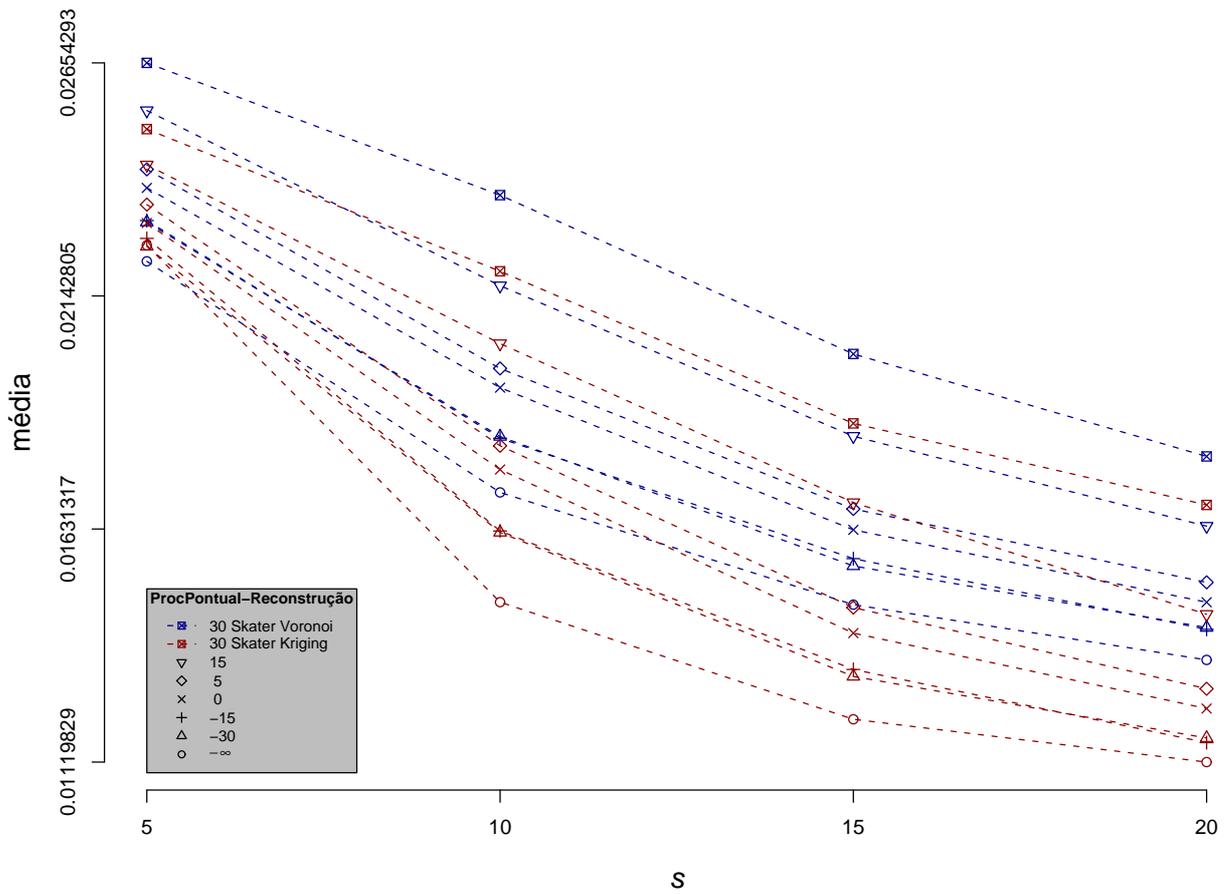


Figura 4.38: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3s}$  - Situação2

Através da figura 4.38 mostramos que, assim como ocorre na *situação1*, na *situação2*, indiferentemente quanto ao processo pontual  $a$ , ambos os processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  tendem a aumentar a qualidade da reconstrução à medida que a escala  $s$  for aumentando, ou seja, à medida que a granularidade do fenômeno  $f$  sob observação for diminuindo.

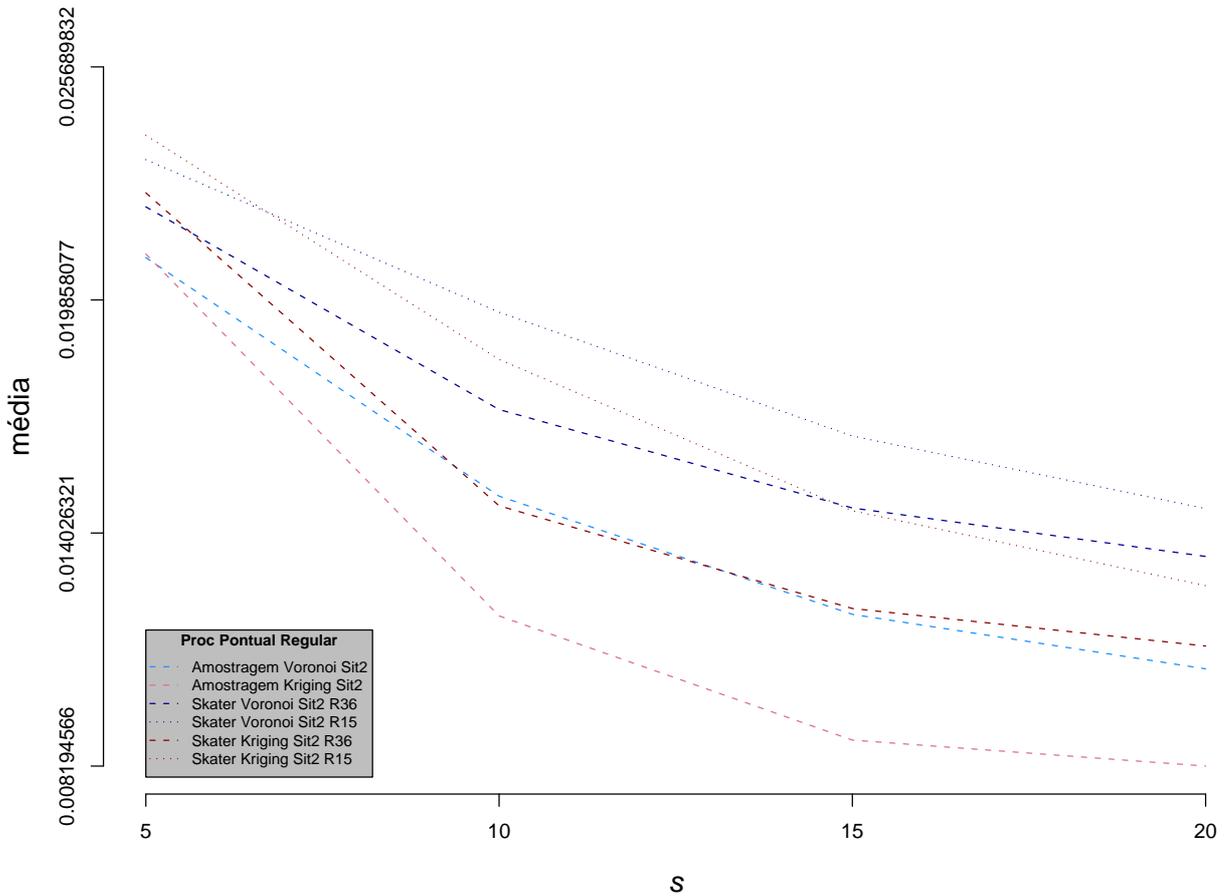


Figura 4.39: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3S}$  - Situação2 com  $r_c = 36$  m e com  $r_c = 15$  m

No início desta seção apontamos que as características de comunicação e de percepção dos sensores *tipo2* modelados para a *situação2* são fatores que influenciam diretamente no desempenho da rede. Em vista disso, decidimos ajustar nossas simulações contemplando uma nova configuração para a característica de comunicação dos sensores *tipo2* definindo um novo raio de comunicação com valor  $r_c = 15$  m. Com esta nova configuração, desejamos colocar em evidência a influência isolada deste fator no desempenho da rede.

Considerando apenas o processo pontual regular  $a = -\infty$ , apresentamos a figura 4.39 ilustrando os resultados obtidos pelos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  aplicados a partir do conjunto de dado  $\Psi_{3S}$  recebido da rede de sensores operando sob as duas diferentes configurações de raio de comunicação: o  $r_c = 36$  m padrão de utilização para *situação2* e o novo  $r_c = 15$  m. Incluímos na figura os resultados das reconstruções para o conjunto de dados de amostragem individual dos sensores ( $\Psi_1$ ), apenas para destacar as contribuições das operações de clusterização e agregação no erro de reconstrução.

Ao compararmos os resultados obtidos, nas simulações, entre as duas configurações de raio de comunicação  $r_c$  unicamente para o processo pontual regular  $a = -\infty$ , criamos a oportunidade de avaliar, exclusivamente, a contribuição ou influência do raio de comunicação para as operações de clusterização e agregação e como conseqüência para a reconstrução.

Constatamos pela figura 4.39 que quanto maior o raio de comunicação  $r_c$  maior a qualidade de reconstrução dos processos de reconstrução  $\Psi_{4V}$  e  $\Psi_{4K}$  aplicados a  $\Psi_{3S}$ , uma vez que quanto maior o número de vizinhos por sensor maior será a homogeneidade dos *clusters* formados pelo SKATER e como conseqüência maior será a qualidade da reconstrução do fenômeno  $f$ .

Na figura 4.40 ilustramos um sensor *tipo2*, ponto em azul, e seu raio de comunicação definido para as duas configurações de raio de comunicação  $r_c$ ,  $r_c = 36$  m e  $r_c = 15$  m. Percebemos que quanto maior a

configuração do raio de comunicação  $r_c$  do sensor *tipo2*, maior o seu número de vizinhos.

Embora essa relação entre raio de comunicação, número de vizinhos e qualidade da reconstrução seja válida para todos os processos pontuais, estamos apenas considerando o processo pontual regular com o objetivo de avaliar especificamente as influências do raio de comunicação e da granularidade do fenômeno à operação de clusterização, agregação e reconstrução. Além disso, com a distribuição regular, evitamos possíveis isolamentos de sensores e os impactos disto nas operações realizadas pela rede de sensores (ver detalhes de implementação na Seção 3.6.3.6, página 43, que tratam do  $r_c$  e da questão do isolamento).

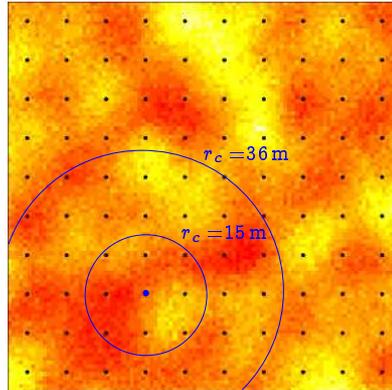


Figura 4.40: Raio de Comunicação  $r_c$  dos sensores *tipo2* com  $r_c = 36$  m e com  $r_c = 15$  m

A figura 4.41 ilustra os resultados obtidos pelos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  aplicados a partir da agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3S}$ ) considerando o processo pontual regular  $a = -\infty$  e as escalas  $s = \{5, 10, 15, 20\}$ . Os resultados foram obtidos para cada uma das duas configurações de raio de comunicação,  $r_c = 36$  m e  $r_c = 15$  m.

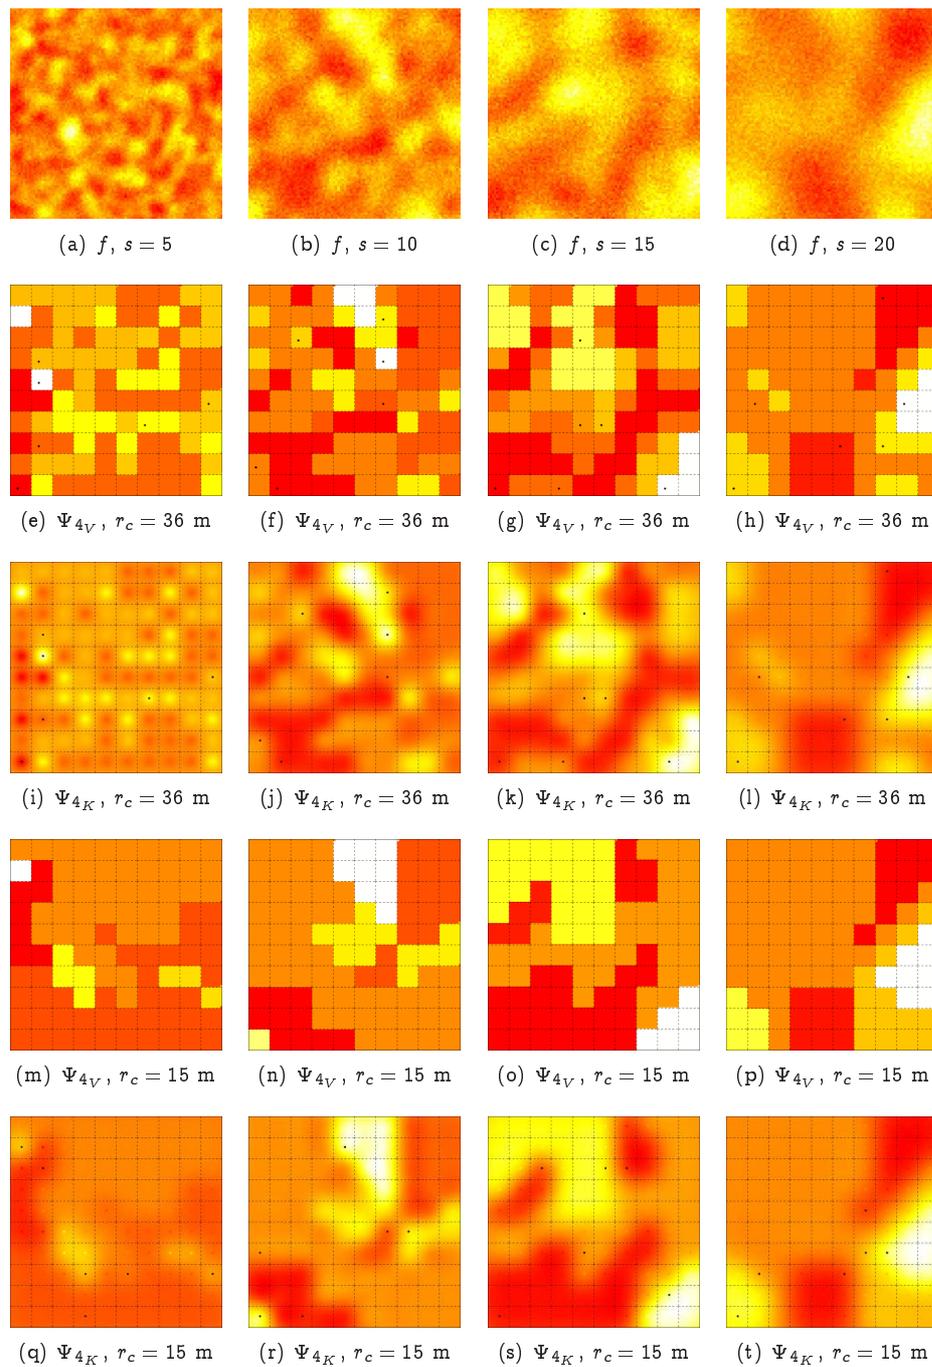


Figura 4.41: Reconstruções por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de  $\Psi_{3S}$  - processo pontual regular e todas escalas  $s$  na *Situação2* com  $r_c = 36 \text{ m}$  e com  $r_c = 15 \text{ m}$

As figuras 4.41(a), 4.41(b), 4.41(c) e 4.41(d) ilustram o fenômeno sendo reconstruído nas escalas  $s = 5$ ,  $s = 10$ ,  $s = 15$  e  $s = 20$ , respectivamente. Abaixo de cada figura do fenômeno com escala  $s$ , encontram-se as diversas reconstruções considerando a mesma escala  $s$ .

As figuras 4.41(e), 4.41(f), 4.41(g) e 4.41(h) representam as reconstruções por Voronoi  $\Psi_{4V}$  para as escalas  $s = 5$ ,  $s = 10$ ,  $s = 15$  e  $s = 20$ , respectivamente, considerando o sensores *tipo2* configurados com  $r_c = 36 \text{ m}$ .

As figuras 4.41(i), 4.41(j), 4.41(k) e 4.41(l) representam as reconstruções por Kriging  $\Psi_{4K}$  para as escalas  $s = 5$ ,  $s = 10$ ,  $s = 15$  e  $s = 20$ , respectivamente, considerando o sensores *tipo2* configurados com  $r_c = 36 \text{ m}$ .

As figuras 4.41(m), 4.41(n), 4.41(o) e 4.41(p) representam as reconstruções por Voronoi  $\Psi_{4V}$  para as escalas  $s = 5$ ,  $s = 10$ ,  $s = 15$  e  $s = 20$ , respectivamente, considerando o sensores *tipo2* configurados com

$r_c = 15$  m.

As figuras 4.41(q), 4.41(r), 4.41(s) e 4.41(t) representam as reconstruções por Kriging  $\Psi_{4K}$  para as escalas  $s = 5$ ,  $s = 10$ ,  $s = 15$  e  $s = 20$ , respectivamente, considerando os sensores *tipo2* configurados com  $r_c = 15$  m.

Pelas figuras, percebemos que para ambos os processos de reconstrução, independentemente de  $r_c$ , quanto maior a escala  $s$ , ou seja quanto menor a granularidade de  $f$ , maior a qualidade da reconstrução obtida. Além disto, para cada configuração  $r_c$ , quanto menor a granularidade de fenômeno  $f$  melhor a qualidade do processos de reconstrução por Kriging  $\Psi_{4K}$  em comparação ao  $\Psi_{4V}$ .

Para cada processo de reconstrução, comparando a qualidade da reconstrução obtida utilizando-se os sensores configurados com  $r_c = 36$  m com a qualidade obtida utilizando-se os sensores com  $r_c = 15$  m, percebemos que as operações de clusterização e agregação realizadas pela rede de sensores configurados com  $r_c = 36$  m resultaram em melhores reconstruções de  $f$ .

## 4.7 Confrontação entre a *Situação1* e a *Situação2*

Nesta seção traçamos um paralelo entre a *situação1* e a *situação2* apresentando e avaliando alguns resultados da reconstrução do fenômeno iluminação  $f$  obtidos pelos processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  aplicados a partir dos conjuntos de dados: (i) amostragens individuais dos sensores ainda não clusterizados ( $\Psi_1$ ) e (ii) agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3S}$ ).

Para compararmos estas situações, algumas condições foram estabelecidas e, quando necessário, alguns ajustes em nossas simulações foram realizados de forma a garantir um equilíbrio entre as situações quanto às características de percepção e de comunicação (para mais detalhes, ver Seção 3.6.4 na página 44).

Conforme exposto na Seção 3.6.4.1 (página 44), considerando a condição da distribuição regular dos sensores definida pelo processo pontual regular  $a = -\infty$  e o fato de que em ambas as situações a área média de percepção dos sensores é de  $100 \text{ m}^2$ , podemos considerar como estabelecido o equilíbrio das características de percepção entre a *situação1* e a *situação2* (sugerimos que o leitor verifique as figuras 3.29(a) e 3.29(b), página 45).

Considerando os demais processos pontuais, percebemos pelas figuras 3.29(c) e 3.29(d) (página 45), os impactos causados pela atratividade ao processos de amostragem  $\Psi_1$  da *situação2*. Quanto mais atrativo o processos de distribuição dos sensores, maior a falta de cobertura de percepção pela rede de sensores na região monitorada.

O equilíbrio das características de comunicação entre a *situação1* e a *situação2* foi definido considerando as seguintes condições: (i) distribuição regular dos sensores e (ii) equiparação do número máximo de vizinhos por sensor entre as situações (ver detalhes na Seção 3.6.4.1).

Ao restringirmos as simulações para o processo pontual regular e ajustarmos o raio de comunicação dos sensores *tipo2* da *situação2* reduzindo  $r_c$  do valor padrão  $r_c = 36$  m para o valor  $r_c = 15$  m, igualamos em oito, o número máximo de vizinhos por sensor para ambas a situações, definindo assim o equilíbrio quanto às características de comunicação. Convidamos o leitor a verificar na figura 3.30 (página 46) a relação de equilíbrio de comunicação estabelecida nessas condições entre a *situação1* e a *situação2*.

Estabelecidas as condições de equilíbrio entre as situações quanto as características de percepção (área média de percepção dos sensores e sua distribuição regular) e de comunicação (distribuição regular do sensores e equiparação das áreas de comunicação), mais adiante nesta seção (página 92), avaliamos os resultados da reconstrução por Voronoi e por Kriging aplicados a partir  $\Psi_{3S}$  traçando um paralelo entre a *situação1* e a *situação2*.

A seguir, considerando todos os processos pontuais  $a = \{-\infty, -30, -15, 0, 5, 15, 30\}$  e todas as escalas  $s = \{5, 10, 15, 20\}$  e , avaliamos os resultados da reconstrução por Voronoi e por Kriging aplicados a partir da amostragem  $\Psi_1$  confrontando a *situação1* com a *situação2*.

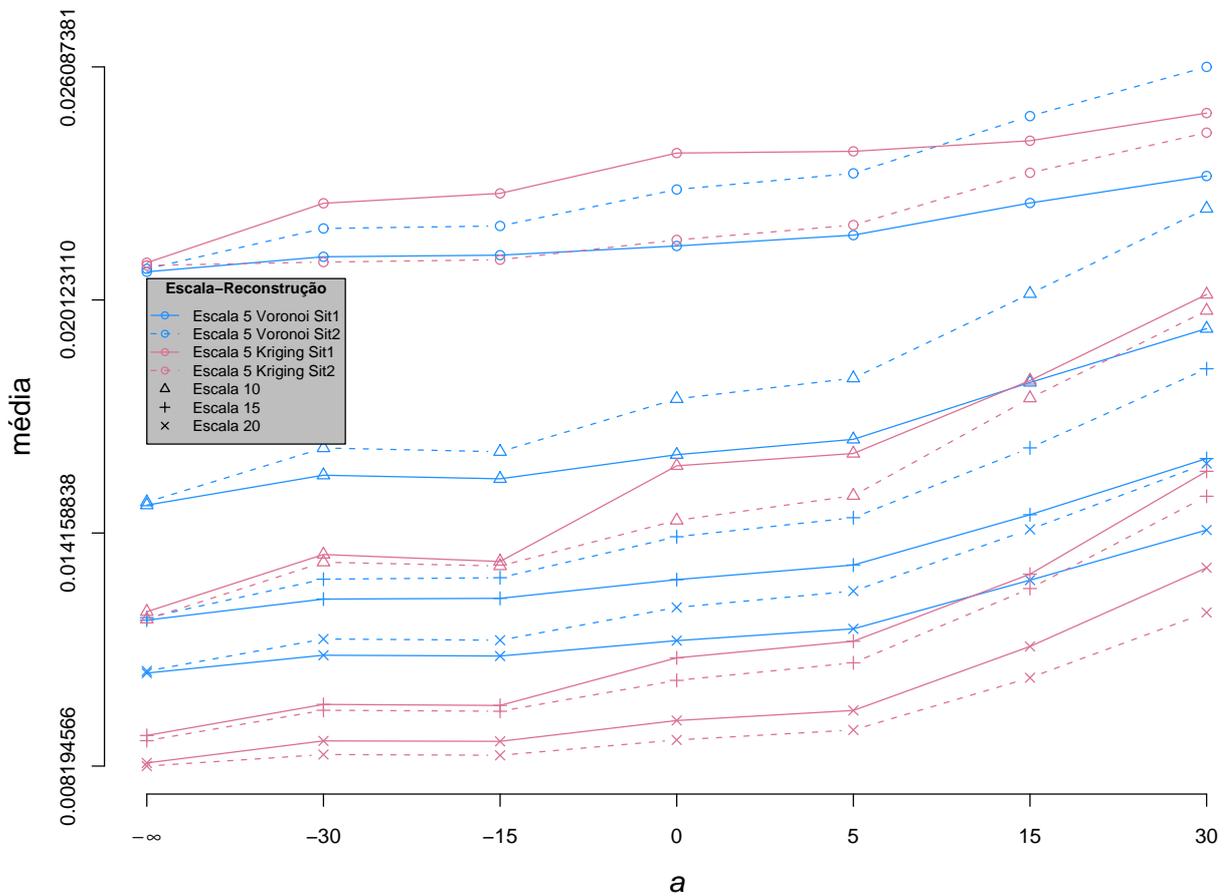


Figura 4.42: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_1$  - Situação1 e Situação2

Na figura 4.42 ilustramos a reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de amostragem  $\Psi_1$  para a *situação1* e para a *situação2* considerando todos os processos pontuais  $a$  e escalas  $s$ .

Ao compararmos os resultados da reconstrução por Voronoi entre a *situação1* e a *situação2* para todos os processos pontuais e todas as escalas, Voronoi reconstruiu melhor quando aplicado à *situação1* do que quando aplicado à *situação2* em todas as escalas  $s$  e para os processos pontuais  $a = \{-30, -15, -0, 5, 15, 30\}$ . Quanto ao processo pontual regular  $a = -\infty$  nas escalas  $s = \{5, 10, 15, 20\}$  não podemos afirmar, pelo intervalo de confiança de 99%, que as medidas diferem significativamente.

Quanto à reconstrução por Kriging, embora pelo gráfico possamos visualizar menores erros nos resultados da reconstrução para a *situação2* em comparação com a reconstrução para a *situação1*, pelo intervalo de confiança de 99%, não podemos dizer diferirem significativamente as medidas das seguintes comparações: escala  $s = 20$  com processos pontuais  $a = \{15, 30\}$ ,  $s = 15$  com  $a = \{-30, -15, 15, 30\}$ ,  $s = 10$  com  $a = \{-\infty, -30, -15, 15, 30\}$  e  $s = 5$  com  $a = \{-\infty, 30\}$ .

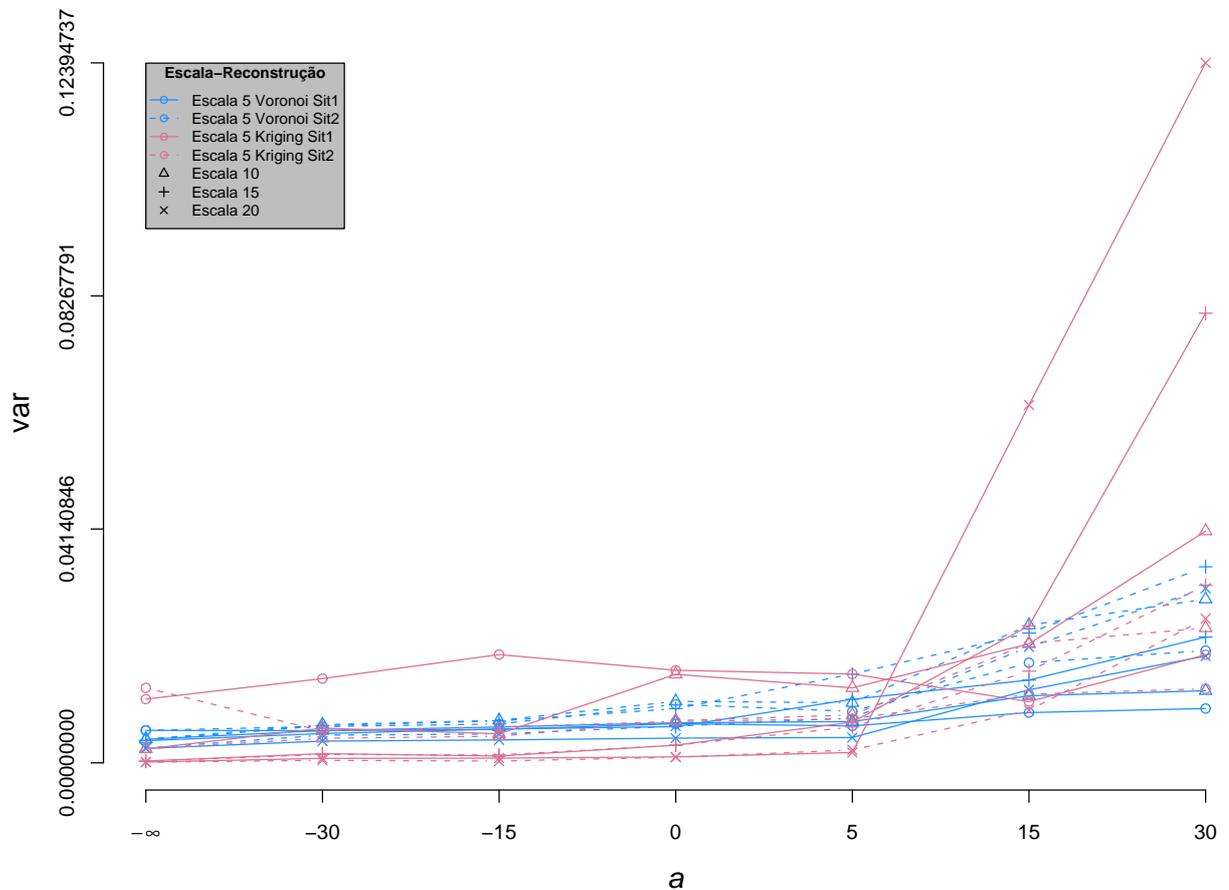


Figura 4.43: Variância do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_1$  - Situação1 e Situação2

Apresentamos a figura 4.43 apenas para ilustrar a diminuição, na *situação2*, da variância do erro de reconstrução por Kriging a partir da amostragem  $\Psi_1$  para os processos pontuais mais atrativos  $a = \{15, 30\}$  nas escalas  $s = \{15, 20\}$  quando comparada com a variância do erro na mesma reconstrução para a *situação1*.

Considerando o fenômeno  $f$  com escala  $s = 20$  e todos os processos pontuais  $a$ , a figura 4.44 ilustra uma comparação entre a reconstrução por Voronoi  $\Psi_{4V}$  a partir da amostragem  $\Psi_1$  para a *situação1* com a reconstrução por Voronoi a partir do mesmo conjunto  $\Psi_1$  para a *situação2*.

As figuras 4.44(b), 4.44(c), 4.44(d), 4.44(e), 4.44(f), 4.44(g) e 4.44(h) mostram a reconstrução de  $f$  para os processos pontuais  $a = -\infty, a = -30, a = -15, a = 0, a = 5, a = 15$  e  $a = 30$ , respectivamente, na *situação1*. As figuras 4.44(j), 4.44(k), 4.44(l), 4.44(m), 4.44(n), 4.44(o) e 4.44(p) mostram a reconstrução de  $f$  para os processos pontuais  $a = -\infty, a = -30, a = -15, a = 0, a = 5, a = 15$  e  $a = 30$ , respectivamente, na *situação2*.

Auxiliados pelos resultados e a avaliação da figura 4.42, ao fazermos uma comparação visual entre os resultados para cada processo pontual, podemos perceber que quanto mais atrativo o processo pontual maior a vantagem da qualidade da reconstrução por Voronoi na *situação1* em comparação com a reconstrução por Voronoi na *situação2*. Notemos que no processo pontual regular  $a = -\infty$  a diferença é imperceptível. Na *situação2*, quanto maior a atratividade maior a área não percebida pela operação de amostragem realizada pela rede e assim menor a qualidade da reconstrução de  $f$  a partir da amostragem individual dos sensores. Na *situação1* não ocorrem áreas sem cobertura de percepção com a atratividade, uma vez que, embora longe da realidade, a amostragem é definida pelo particionamento completo da área sob monitoração.

Ao analisarmos a reconstrução por Voronoi entre a *situação1* e a *situação2*, mostramos a contribuição das características de percepção dos sensores ou ainda, da falta de cobertura, para a qualidade da

reconstrução do fenômeno  $f$ .

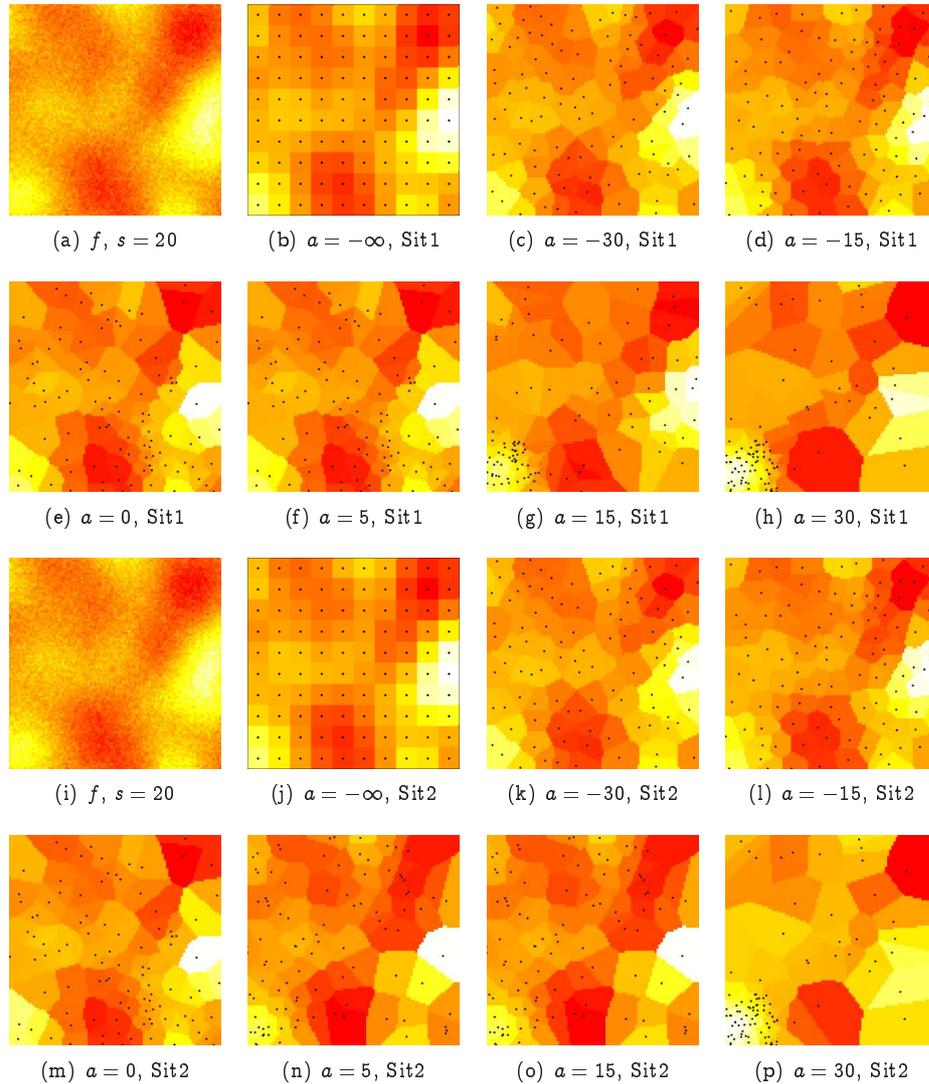


Figura 4.44: Reconstruções  $\Psi_{4v}$  a partir de  $\Psi_1$  - *situação1* (Sit1) e *situação2* (Sit2)

Na figura 4.45 mostramos os resultados da reconstrução por Kriging  $\Psi_{4K}$  a partir de  $\Psi_1$  comparando a qualidade da reconstrução obtida para a *situação1* com a qualidade da reconstrução obtida para a *situação2* considerando o fenômeno na mesma escala  $s = 20$  e todos os processos pontuais  $a$ .

A figura 4.45, embora relativa à reconstrução por Kriging, encontra-se organizada de forma análoga à figura 4.44.

Com o processo de reconstrução por Kriging  $\Psi_{4K}$ , conforme os resultados mostrados pela figura 4.42 e mantidas as ressalvas quanto às avaliações dos intervalos de confiança, a reconstrução para a *situação2* passa a apresentar melhor qualidade do que a reconstrução para a *situação1*.

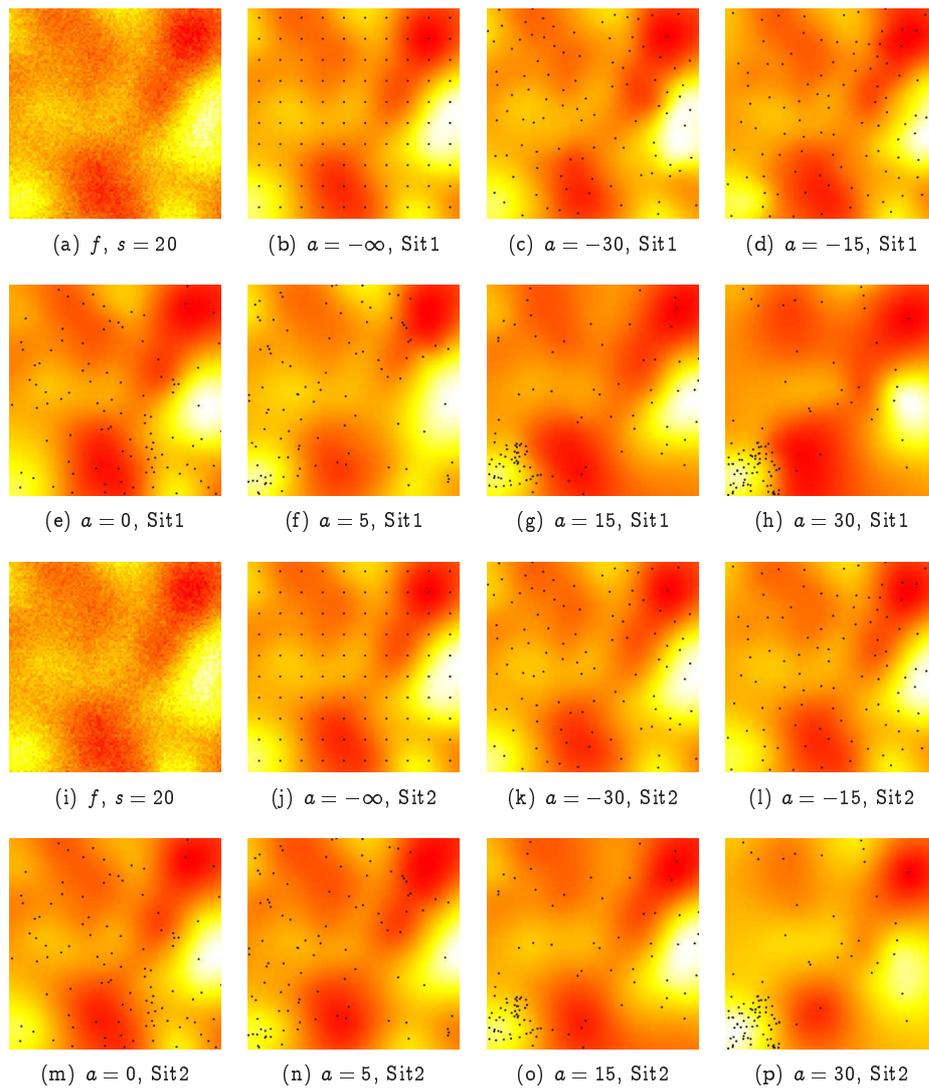


Figura 4.45: Reconstruções  $\Psi_{4K}$  a partir de  $\Psi_1$  - *situação1* (Sit1) e *situação2* (Sit2)

Na reconstrução do fenômeno  $f$  com escala  $s = 20$  podemos perceber, pela figura 4.45, que a reconstrução por Kriging para *situação2* apresenta qualidade superior ou no mínimo similar à reconstrução para a *situação1*. A amostragem realizada na *situação2* (área percepção radial) passa a contribuir mais positivamente que a amostragem para a *situação1* (célula de Voronoi como área de percepção) para a tarefa de estimação e reconstrução realizada pelo Kriging, especialmente nos processos pontuais menos atrativos.

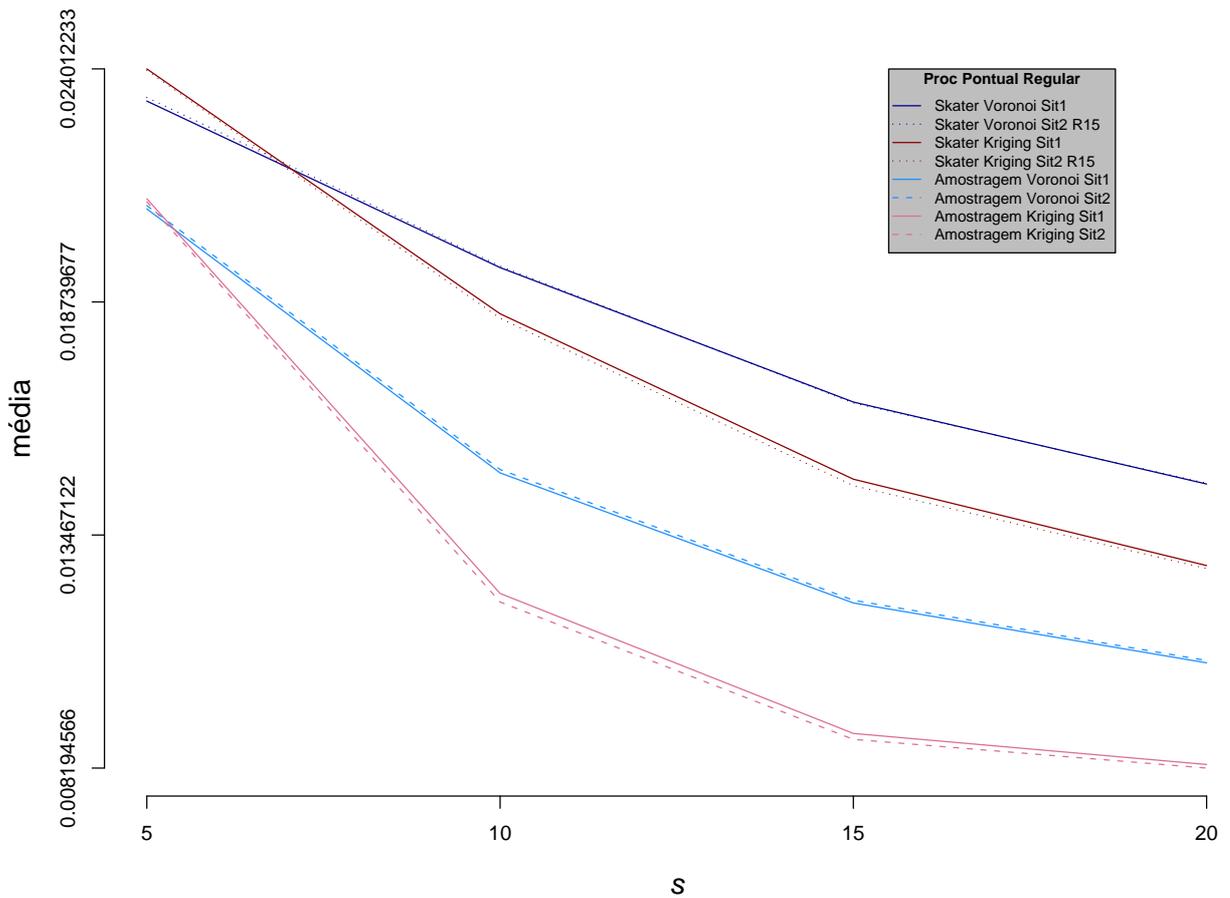


Figura 4.46: Média do erro de Reconstrução por Voronoi e por Kriging a partir de  $\Psi_{3_S}$  com Processo Regular - *Situação1* e *Situação2* com  $r_c = 15$  m

Considerando apenas o processo pontual regular  $a = -\infty$  e todas as escalas  $s$ , a figura 4.46 ilustra os resultados obtidos pelos processos de reconstrução por Voronoi  $\Psi_{4_V}$  e por Kriging  $\Psi_{4_K}$  aplicados a partir da agregação dos dados clusterizados pelo SKATER ( $\Psi_{3_S}$ ) na *Situação1* e na *Situação2* com  $r_c = 15$  m e aplicados, também, a partir da amostragem ( $\Psi_1$ ) na *Situação1* e na *Situação2*.

Percebemos pela figura que, para o processo pontual regular nas escalas maiores  $s = \{10, 15, 20\}$ , independentemente da situação (*Situação1*, *Situação2* ou *Situação2* com  $r_c = 15$  m), a reconstrução de  $f$  por Kriging a partir de  $\Psi_1$  e a partir de  $\Psi_{3_S}$  apresenta melhores resultados que a reconstrução por Voronoi a partir de  $\Psi_1$  e a partir de  $\Psi_{3_S}$ , respectivamente.

Para a escala  $s = 5$ , a reconstrução por Voronoi  $\Psi_{4_V}$  a partir de  $\Psi_{3_S}$  resulta numa melhor qualidade quando comparada com a reconstrução por  $\Psi_{4_K}$ . Já quanto à reconstrução da amostragem  $\Psi_1$ , pelo intervalo de confiança de 99%, não podemos dizer qual dos dois processos de reconstrução obteve melhor resultado.

Considerando isoladamente cada um dos processos de reconstrução, pelo intervalo de confiança de 99%, não podemos dizer que os resultados da reconstrução a partir de  $\Psi_{3_S}$  entre a *Situação1* e a *Situação2* com  $r_c = 15$  m diferem significativamente. O mesmo podemos dizer para a reconstrução por Voronoi a partir de  $\Psi_1$  entre a *Situação1* e a *Situação2*.

A reconstrução por Kriging  $\Psi_{4_K}$  a partir de  $\Psi_1$  para a *situação2* obteve melhores resultados que os obtidos para a *situação1* para as escalas maiores  $s = \{15, 20\}$ . Já nas reconstruções de fenômenos com maior granularidade ( $s = \{5, 10\}$ ), pelos intervalos de confiança de 99% nada podemos afirmar quanto a significância das diferenças.

A figura 4.47 apresenta algumas reconstruções de  $f$ , nas escalas  $s = \{5, 10, 15, 20\}$ , obtidas pelo processo de reconstrução por Voronoi  $\Psi_{4_V}$  a partir de  $\Psi_{3_S}$  considerando o processo pontual regular na *Situação1* e na *Situação2* com  $r_c = 15$  m.

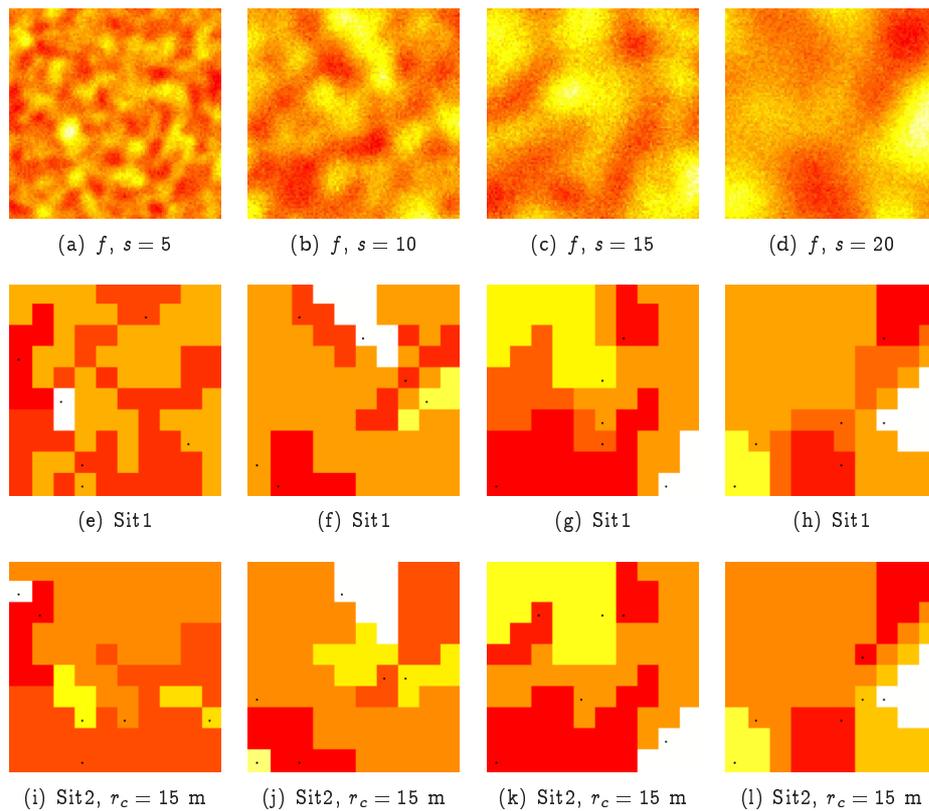


Figura 4.47: Reconstruções por Voronoi  $\Psi_{4V}$  a partir de  $\Psi_{3S}$  - processo pontual regular e todas escalas  $s$  - *Situação1* e *Situação2* com  $r_c = 15$  m

As figuras 4.47(e), 4.47(f), 4.47(g) e 4.47(h) representam as reconstruções de  $f$  nas escalas  $s = 5$ ,  $s = 10$ ,  $s = 15$  e  $s = 20$ , respectivamente, obtidas por  $\Psi_{4V}$  para a *situação1*. As figuras 4.47(i), 4.47(j), 4.47(k) e 4.47(l) representam as reconstruções de  $f$  nas escalas  $s = 5$ ,  $s = 10$ ,  $s = 15$  e  $s = 20$ , respectivamente, obtidas por  $\Psi_{4V}$  para a *situação2* com  $r_c = 15$  m.

Uma vez que, ao considerarmos o processo pontual regular, as condições de percepção entre a *situação1* e *situação2* com  $r_c = 15$  m estão equiparadas, percebemos pela figura 4.47 não haver diferenças significativas ou mesmo perceptíveis entre os resultados de reconstrução obtidos para as duas situações.

Considerando a reconstrução por Kriging, a figura 4.48 apresenta as mesmas comparações apresentadas pela figura 4.47.

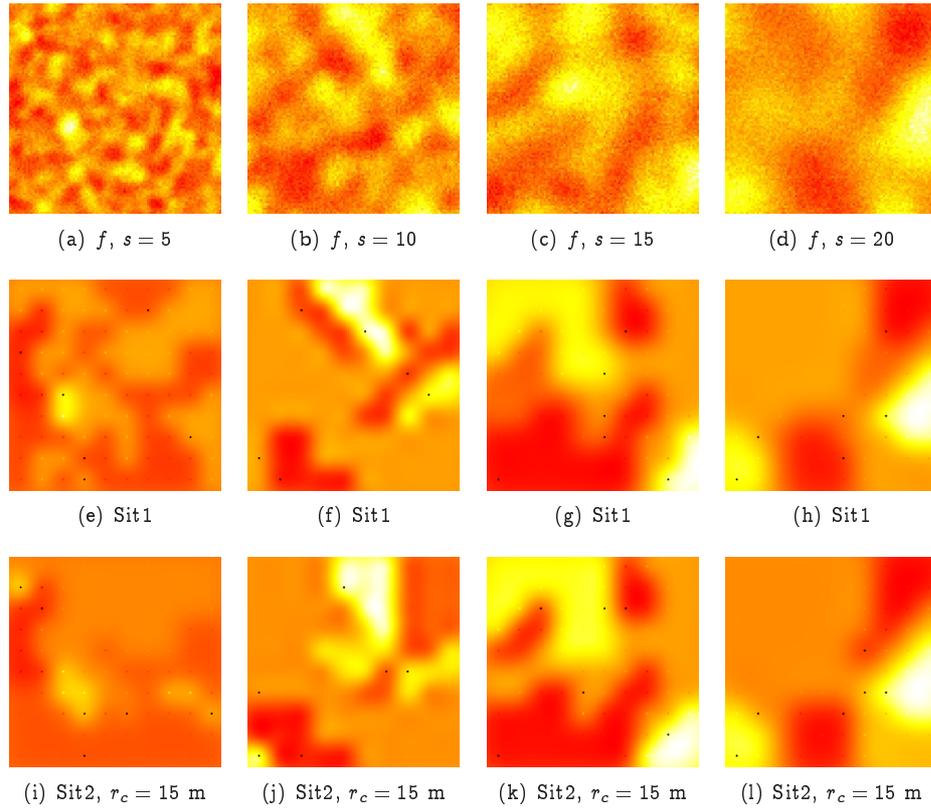


Figura 4.48: Reconstruções por Kriging  $\Psi_{4K}$  a partir de  $\Psi_{3S}$  - processo pontual regular e todas escalas  $s$  - *Situação 1* e *Situação 2* com  $r_c = 15$  m

Embora, nesta figura, possamos mais facilmente comparar visualmente os resultados obtidos para as duas situações face aos contornos da reconstrução por Kriging, novamente percebemos que as diferenças das reconstrução entre as duas situações não são significativas. Isto ocorre indiferentemente quanto à granularidade do fenômeno  $f$ . Uma vez que as características de amostragem para a *situação 1* e a *situação 2* com  $r_c = 15$  m encontram-se equilibradas, os resultados das operações de clusterização e agregação  $\Psi_{3S}$  nas duas situações são similares, resultando, também, em reconstruções similares.

## 4.8 Resumo dos Resultados

Complementando as avaliações expostas acima, concluímos este capítulo apresentando um comparativo quantitativo dos impactos causados à qualidade da reconstrução pela granularidade (escala) do fenômeno sob observação, pela atratividade da distribuição dos sensores na área monitorada e pelos protocolos de clusterização. Consideraremos apenas a *situação 2* por ter sido modelada buscando uma maior aproximação com a realidade (amostragem definida pela função de resposta radial dos sensores *tipo 2*, ver Seção 3.3.5 na página 24).

Na tabela 4.4 quantificamos os erros de reconstrução do fenômeno  $f$  contribuídos pela granularidade de  $f$  (escala  $s = \{5, 10, 15, 20\}$ ) e pela atratividade da distribuição dos sensores (processos pontuais  $a = \{-\infty, -30, -15, 0, 5, 15, 30\}$ ), considerando a reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$  a partir de amostragem  $\Psi_1$  na *situação 2*.

Na *situação 2*, dentre todos os valores estimados, o menor erro de reconstrução do fenômeno  $f$  a partir da amostragem  $\Psi_1$  foi  $\hat{\mu} = 8.19 \cdot 10^{-3}$ , o obtido pelo processo de reconstrução por Kriging  $\Psi_{4K}$  para o processo pontual regular  $a = -\infty$  com a escala  $s = 20$ . Na tabela 4.4, cada valor é mostrado como uma proporção deste menor valor identificado pela célula na cor cinza.

Comparando isoladamente cada processo de reconstrução, percebemos que o erro aumenta com a escala  $s$  e com a atratividade  $a$ . Considerando o processo pontual regular  $a = -\infty$  e processo de reconstrução por Kriging, ao aumentarmos a granularidade da escala  $s = 20$  para a escala  $s = 5$  o erro de reconstrução a partir da amostragem aumenta aproximadamente 2.6 vezes. Para o processo de reconstrução por Voronoi,

este aumento é de aproximadamente duas vezes. Para todos os demais processos pontuais, em ambos os processos de reconstrução, verificamos na tabela que o erro aumenta com a escala.

Ainda considerando isoladamente cada processo de reconstrução, fixando a escala  $s$ , o erro de reconstrução aumenta com a atratividade. Considerando a escala  $s = 20$  e o processo de reconstrução por Kriging, ao aumentarmos o processo pontual de  $a = -\infty$  (o mais repulsivo) para  $a = 30$  (o mais atrativo), o erro de reconstrução a partir da amostragem aumenta aproximadamente 1.5 vezes. Para o processo de reconstrução por Voronoi, este aumento é na mesma proporção de  $1.945/1.2969 \approx 1.5$  vezes. Para as demais escalas, novamente em ambos os processos de reconstrução, verificamos na tabela que o erro aumenta com a atratividade, exceto para o processo pontual atrativo  $a = -15$  nas escalas  $s = \{10, 15, 20\}$  (ver gráficos e avaliações das figuras 4.24 e 4.26, nas páginas 69 e 71, respectivamente).

Comparando os resultados dos processos de reconstrução de  $f$  a partir amostragem  $\Psi_1$ , constatamos pela tabela 4.4 que a reconstrução por Kriging  $\Psi_{4_K}$  obtém melhores resultados (menores erros) que a reconstrução por Voronoi  $\Psi_{4_V}$ , para todos os casos de  $a$  e  $s$ . Para a escala  $s = 20$ , comparando Kriging e Voronoi para cada processo pontual  $a$ , o erro de reconstrução por Voronoi é aproximadamente 34% maior que o erro de reconstrução por Kriging. Para a escala  $s = 15$ , essa taxa é de aproximadamente 32%. Na escala  $s = 10$ , tal taxa cai para 19%. E na escala  $s = 5$ , o erro de reconstrução por Voronoi se aproxima do erro de reconstrução por Kriging sendo maior aproximadamente 4%, inclusive apresentando menor erro para o processo pontual regular.

Reconstrução	Processo Pontual	Escalas			
		$s = 20$	$s = 15$	$s = 10$	$s = 5$
$\Psi_1$ por Kriging	$a = -\infty$	1.0000	1.0793	1.4585	2.5635
$\Psi_1$ por Kriging	$a = -30$	1.0361	1.1743	1.6366	2.5738
$\Psi_1$ por Kriging	$a = -15$	1.0337	1.1712	1.6248	2.5812
$\Psi_1$ por Kriging	$a = 0$	1.0816	1.2677	1.7672	2.6431
$\Psi_1$ por Kriging	$a = 5$	1.1128	1.3225	1.8444	2.6895
$\Psi_1$ por Kriging	$a = 15$	1.2759	1.5544	2.1489	2.8527
$\Psi_1$ por Kriging	$a = 30$	1.4796	1.8426	2.4224	2.9781
$\Psi_1$ por Voronoi	$a = -\infty$	1.2969	1.4633	1.8242	2.5528
$\Psi_1$ por Voronoi	$a = -30$	1.3968	1.5836	1.9933	2.6789
$\Psi_1$ por Voronoi	$a = -15$	1.3930	1.5882	1.9816	2.6867
$\Psi_1$ por Voronoi	$a = 0$	1.4954	1.7162	2.1468	2.8006
$\Psi_1$ por Voronoi	$a = 5$	1.5466	1.7756	2.2113	2.8510
$\Psi_1$ por Voronoi	$a = 15$	1.7393	1.9937	2.4750	3.0298
$\Psi_1$ por Voronoi	$a = 30$	1.9450	2.2408	2.7411	3.1835

Tabela 4.4: Análise quantitativa: *situação2*, Amostragem  $\Psi_1$ , Voronoi e Kriging

Na tabela 4.5 comparamos quantitativamente, para *situação2*, o erro de reconstrução por Kriging a partir da amostragem  $\Psi_1$  com o erro de reconstrução por Kriging a partir dos dados de agregação dos sensores clusterizados pela técnica SKATER ( $\Psi_{3_S}$ ), considerando todos os processos pontuais  $a$  e todas as escalas  $s$ . Ao compararmos estes erros, estamos evidenciando as influências que as operação de clusterização e agregação realizadas pela rede de sensores exercem sobre o resultado final dos processos de reconstrução.

Novamente, o valor de referência é o erro  $\hat{\mu} = 8.19 \cdot 10^{-3}$  obtido pelo processo de reconstrução por Kriging a partir da amostragem  $\Psi_1$  para o processo pontual regular  $a = -\infty$  com escala  $s = 20$ . Na tabela 4.4, este valor é identificado pela célula na cor cinza.

Comparando  $\Psi_1$  com  $\Psi_{3_S}$  em cada escala  $s$  e para todos os processos pontuais  $a$ , percebemos que em todos os casos o erro de reconstrução por Kriging a partir de  $\Psi_1$  é menor que o erro de reconstrução por Kriging a partir de  $\Psi_{3_S}$ . Para a escala  $s = 20$  e todas os processos pontuais, comparando a reconstrução a partir de  $\Psi_1$  com a reconstrução a partir de  $\Psi_{3_S}$ , o erro de reconstrução a partir do SKATER  $\Psi_{3_S}$  é aproximadamente 38% maior. Para a escala  $s = 15$ , essa taxa é de aproximadamente 33%. Para a escala  $s = 10$ , há uma queda dessa taxa Por fim para aproximadamente 19%. E, novamente, na escala  $s = 5$ , o erro de reconstrução a partir  $\Psi_{3_S}$  se aproxima do erro de reconstrução a partir de  $\Psi_1$ , sendo maior aproximadamente 5%.

Reconstrução	Processo Pontual	Escalas			
		$s = 20$	$s = 15$	$s = 10$	$s = 5$
$\Psi_1$ por Kriging	$a = -\infty$	1.0000	1.0793	1.4585	2.5635
$\Psi_{3_S}$ por Kriging	$a = -\infty$	1.3666	1.4812	1.7949	2.7505
$\Psi_1$ por Kriging	$a = -30$	1.0361	1.1743	1.6366	2.5738
$\Psi_{3_S}$ por Kriging	$a = -30$	1.4310	1.5959	1.9817	2.7476
$\Psi_1$ por Kriging	$a = -15$	1.0337	1.1712	1.6248	2.5812
$\Psi_{3_S}$ por Kriging	$a = -15$	1.4186	1.6147	1.9855	2.7689
$\Psi_1$ por Kriging	$a = 0$	1.0816	1.2677	1.7672	2.6431
$\Psi_{3_S}$ por Kriging	$a = 0$	1.5099	1.7120	2.1501	2.8103
$\Psi_1$ por Kriging	$a = 5$	1.1128	1.3225	1.8444	2.6895
$\Psi_{3_S}$ por Kriging	$a = 5$	1.5630	1.7804	2.2136	2.8596
$\Psi_1$ por Kriging	$a = 15$	1.2759	1.5544	2.1489	2.8527
$\Psi_{3_S}$ por Kriging	$a = 15$	1.7624	2.0616	2.4874	2.9659
$\Psi_1$ por Kriging	$a = 30$	1.4796	1.8426	2.4224	2.9781
$\Psi_{3_S}$ por Kriging	$a = 30$	2.0552	2.2736	2.6809	3.0617

Tabela 4.5: Análise quantitativa: *situação2*, Amostragem  $\Psi_1$  e Agregação/Clusterização  $\Psi_{3_S}$ , reconstrução por Kriging

Na tabela 4.6 apresentamos uma comparação quantitativa entre o erro de reconstrução por Kriging a partir de  $\Psi_{3_S}$  (SKATER) com o erro de reconstrução por Kriging a partir dos dados de agregação dos sensores clusterizados pela técnica LEACH ( $\Psi_{3_S}$ ) para todos os processos pontuais  $a$  e todas as escalas  $s$ , considerando a *situação2*. Ao compararmos os erros entre estas duas técnicas, evidenciamos o ganho ou a perda na qualidade final do processo de reconstrução ao considerarmos ou não a correlação dos dados nas operações realizadas pela rede de sensores.

Neste caso, o valor de referência é o erro  $\hat{\mu} = 11.198 \cdot 10^{-3}$  obtido pelo processo de reconstrução por Kriging a partir da amostragem  $\Psi_{3_S}$  para o processo pontual regular  $a = -\infty$  com escala  $s = 20$ . Na tabela 4.6, este valor é identificado pela célula na cor cinza.

Pela tabela, percebemos que em ambas as técnicas, o erro de reconstrução é crescente com a granularidade e com a atratividade.

Reconstrução	Processo Pontual	Escalas			
		$s = 20$	$s = 15$	$s = 10$	$s = 5$
$\Psi_{3_S}$ por Kriging	$a = -\infty$	1.0000	1.0839	1.3134	2.0127
$\Psi_{3_S}$ por Kriging	$a = -30$	1.0472	1.1679	1.4501	2.0106
$\Psi_{3_S}$ por Kriging	$a = -15$	1.0381	1.1816	1.4529	2.0262
$\Psi_{3_S}$ por Kriging	$a = 0$	1.1049	1.2528	1.5734	2.0565
$\Psi_{3_S}$ por Kriging	$a = 5$	1.1437	1.3028	1.6199	2.0926
$\Psi_{3_S}$ por Kriging	$a = 15$	1.2897	1.5086	1.8202	2.1704
$\Psi_{3_S}$ por Kriging	$a = 30$	1.5039	1.6637	1.9618	2.2405
$\Psi_{3_L}$ por Kriging	$a = -\infty$	1.7217	1.9013	2.1554	2.2950
$\Psi_{3_L}$ por Kriging	$a = -30$	1.7368	1.9333	2.1604	2.3041
$\Psi_{3_L}$ por Kriging	$a = -15$	1.7290	1.9120	2.1714	2.3023
$\Psi_{3_L}$ por Kriging	$a = 0$	1.7497	1.9569	2.1784	2.3094
$\Psi_{3_L}$ por Kriging	$a = 5$	1.7848	1.9630	2.1918	2.3148
$\Psi_{3_L}$ por Kriging	$a = 15$	1.8095	1.9984	2.2247	2.3280
$\Psi_{3_L}$ por Kriging	$a = 30$	1.8068	2.0214	2.2232	2.3427

Tabela 4.6: Análise quantitativa: *situação2*, Agregação/Clusterização SKATER  $\Psi_{3_S}$  e LEACH  $\Psi_{3_L}$ , reconstrução por Kriging

Comparando  $\Psi_{3_S}$  com  $\Psi_{3_L}$  em cada escala  $s$  e para todos os processos pontuais  $a$ , percebemos que em todos os casos o erro de reconstrução por Kriging a partir de  $\Psi_{3_S}$  é menor que o erro de reconstrução por Kriging a partir de  $\Psi_{3_L}$ . Para a escala  $s = 20$  e todas os processos pontuais, comparando a reconstrução a partir de  $\Psi_{3_S}$  (SKATER) com a reconstrução a partir de  $\Psi_{3_L}$  (LEACH), o erro de reconstrução a partir do LEACH  $\Psi_{3_L}$  é aproximadamente 54% maior. Para a escala  $s = 15$ , o erro a partir  $\Psi_{3_L}$  é de

aproximadamente 51% maior. Para a escala  $s = 10$ , essa taxa passa a ser aproximadamente 38%. E na escala  $s = 5$ , o erro de reconstrução a partir  $\Psi_{3L}$  se aproxima do erro de reconstrução a partir de  $\Psi_{3S}$ , sendo maior aproximadamente 11%.

Os resultados mostrados na tabela 4.6 reforçam os benefícios do SKATER frente ao LEACH quanto à qualidade da reconstrução de  $f$  ao considerar a correlação dos dados durante o processo de clusterização.

Este capítulo mostrou os resultados obtidos ao aplicar a proposta de análise do desempenho de redes de sensores sem fios em diversas situações de interesse. Esses resultados foram exibidos de forma tabular e gráfica, e os mesmos corroboram a hipótese inicial deste trabalho, isto é, diversos fatores influem no erro de reconstrução do sinal amostrado e é possível quantificar o seu efeito por meio de um ensaio Monte Carlo. O próximo capítulo apresenta as conclusões de forma resumida.

# Capítulo 5

## Conclusões

Dentre as diversas motivações que nos levaram a elaboração deste trabalho, podemos citar

- o potencial tecnológico, a economia de recursos e a viabilidade de execução das atuais redes de sensores sem fios (*WSN*);
- o crescente interesse acadêmico e comercial pelas *WSN*;
- as limitações atuais impostas às pesquisas dos biomas florestais (a exemplo da *Drendonáutica*, com altos custos financeiros, de acessibilidade e tempo), ver Seção 3.1;
- a visão e modelagem da *WSN* como um processo de amostragem, clusterização, agregação e reconstrução de fenômenos observáveis;
- a aplicação desse modelo a uma experiência de interesse real (monitoração da iluminação em uma floresta), por meio de simulações estruturadas de acordo com um estudo Monte Carlo;
- a extração de informações do modelo e avaliação dos impactos sobre a qualidade da reconstrução do fenômeno monitorado causados por fatores como: (i) a granularidade (escala) do fenômeno sob monitoração, (ii) o número de sensores e suas características de percepção/comunicação, (iii) a distribuição dos sensores e (iv) os protocolos de clusterização;

No capítulo 2, apresentamos a rede de sensores sem fios no contexto da aquisição de informação, trazendo ao leitor uma revisão bibliográfica relacionada ao tema bem como alguns conceitos preliminares aos demais capítulos.

Na Seção 3.2 do capítulo 3 propomos nosso modelo genérico (ver figura 3.2, página 16), detalhando cada uma das suas abstrações na Seção 3.3 (página 17) e defendendo sua flexibilidade na Seção 3.4 (página 37).

Ainda no capítulo 3, definimos a estrutura das simulações de acordo com o estudo Monte Carlo (ver Seção 3.5, página 40) e apresentamos os detalhes de implementação e execução das simulações na Seção 3.6, página 40.

Por fim, apresentamos no capítulo 4 uma avaliação dos impactos causados pelos fatores supramencionados na qualidade da reconstrução do fenômeno  $f$  sob monitoração quando aplicados os processos de reconstrução por Voronoi  $\Psi_{4V}$  e por Kriging  $\Psi_{4K}$ . Estes dois processos foram aplicados considerando como entrada um dos três conjuntos de dados resultantes das operações da rede de sensores: (i) amostragens individuais dos sensores ainda não clusterizados ( $\Psi_1$ ), (ii) agregação dos dados amostrados por sensores clusterizados pela técnica LEACH ( $\Psi_{3L}$ ) e (iii) agregação sobre os dados dos sensores clusterizados através da técnica SKATER ( $\Psi_{3S}$ ). Além disto, as simulações foram consideradas em três contextos distintos: (i) *situação1*, (ii) *situação2* e (iii) confrontação entre a *situação1* e *situação2* (ver descrições das avaliações na Seção 4.2, página 47).

Com os resultados e avaliações apresentados no capítulo 4, além de uma comparação entre diferentes processos de reconstrução, mostramos os impactos na qualidade de reconstrução de fenômeno  $f$  causados pelos fatores

- granularidade do fenômeno sob observação;
- distribuição espacial dos sensores;

- protocolo de clusterização/agregação;

Alguns dos trabalhos futuros que podem ser apontados a partir dos resultados alcançados neste trabalho são os seguintes:

- Uso de outras técnicas de reconstrução; nesta dissertação utilizamos apenas Kriging básico e reconstrução por média sobre células de Voronoi.
- Estudo da reconstrução de sinais não gaussianos e/ou multivariados; nesta dissertação consideramos apenas campos aleatórios gaussianos univariados.
- Formulação de técnicas que, empregando inferência sobre processos pontuais (a distribuição espacial dos sensores) e sobre campos aleatórios sejam capazes de otimizar dinamicamente o desempenho da rede sob diversos aspectos (vida útil, qualidade do sinal, etc.):
  - Propor protocolos não homogêneos, isto é, cujo funcionamento seja resultado da estimação local do contexto. Com isso, esses protocolos poderiam exibir um comportamento diferenciado em áreas mais densamente monitoradas, em regiões onde o fenômeno é mais granular ou ainda naquelas regiões onde a comunicação é prejudicada por obstáculos.
  - Estimar as propriedades da rede para aplicar técnicas de codificação aos dados visando a economia de recursos e a qualidade do funcionamento.
  - Estimar as propriedades da rede para guiar dinamicamente o seu funcionamento pelo uso de controle de densidade, roteamento etc.
- Avaliação do erro de reconstrução com a aplicação de outras técnicas de agregação e fusão de dados.
- A validação do modelo apresentado com a utilização de uma rede real de sensores sem fios.
- A incorporação dos resultados aqui alcançados em um processo automatizado de projeto de redes de sensores sem fios para aplicações específicas.

# Referências Bibliográficas

- Akkaya, K., Demirbas, M. & Aygun, R. S. (2008), 'The impact of data aggregation sensor networks on the performance of wireless', *Wireless Communications & Mobile Computing* **8**(2), 171–193.
- Akyildiz, I. F., Su, W. & Cayirci, Y. S. E. (2002), 'Wireless sensor networks: a survey', *Computer Networks-The International Journal of Computer and Telecommunications Networking* **38**(4), 393–422.
- Al-Karaki, J. N. & Kamal, A. E. (2004), 'Routing techniques in wireless sensor networks: A survey', *IEEE Wireless Communications* **11**(6), 6–28.
- Aquino, A. L. L., Figueiredo, C. M. S., Nakamura, E. F., Frery, A. C., Loureiro, A. A. F. & Fernandes, A. O. (2008), Sensor stream reduction for clustered wireless sensor networks, in 'ACM Symposium on Applied Computing', ACM, Fortaleza, CE, Brazil, pp. 2052–2056.
- Assunção, R. M., Neves, M. C., Câmara, G. & Freitas, C. C. (2006), 'Efficient regionalization techniques for socio-economic geographical units using minimum spanning trees', *International Journal of Geographical Information Science* **20**(7), 797–811.
- Baddeley, A. (2006), Spatial point processes and their application, in W. Weil, ed., 'Stochastic Geometry', Vol. 1892 of *Lecture Notes in Mathematics*, Springer, Berlin, pp. 1–75.
- Baddeley, A. & Turner, R. (2005), 'spatstat: An R package for analyzing spatial point patterns', *Journal of Statistical Software* **12**(6), 1–42. URL <http://www.jstatsoft.org/v12/i06>.
- Baronti, P., Pillai, P., Chook, V. W. C., Chessa, S., Gotta, A. & Hu, Y. F. (2007), 'Wireless sensor networks: A survey on the state of the art and the 802.15.4 and ZigBee standards', *Computer Communications* **30**(7), 1655–1695.
- Batalin, M. A., Rahimi, M., Yu, Y., Liu, D., Kansal, A., Sukhatme, G. S., Kaiser, W. J., Hansen, M., Pottie, G. J., Srivastava, M. & Estrin, D. (2004), Call and response: experiments in sampling the environment, in 'SenSys '04: Proceedings of the 2nd international conference on Embedded networked sensor systems', ACM, New York, NY, USA, pp. 25–38.
- Bollobas, B. (1998), *Modern Graph Theory*, Springer.
- Bustos, O. H., Flesia, A. G. & Frery, A. C. (2001), 'Generalized method for sampling spatially correlated heterogeneous speckled imagery', *EURASIP Journal on Applied Signal Processing* **2001**(2), 89–99.
- Cerpa, A. & Estrin, D. (2004), 'ASCENT: Adaptive self-configuring sensor networks topologies', *IEEE Transactions on Mobile Computing* **3**(3), 272–285.
- Chang, J. H. & Tassiulas, L. (2004), 'Maximum lifetime routing in wireless sensor networks', *IEEE-ACM Transactions on Networking* **12**(4), 609–619.
- Chen, Y. X. & Zhao, Q. (2005), 'On the lifetime of wireless sensor networks', *IEEE Communications Letters* **9**(11), 976–978.
- Chessa, S. & Santi, P. (2002), 'Crash faults identification in wireless sensor networks', *Computer Communications* **25**(14), 1273–1282.
- Crossbow Technology Inc (2008), 'Crossbow technology'. URL <http://www.xbow.com>.

- Dekking, F. M., Kraaikamp, C., Lopuhaä, H. P., & Meester, L. E. (2005), *A Modern Introduction to Probability and Statistics: Understanding Why and How*, Springer.
- Demirkol, I., Ersoy, C. & Alagoz, F. (2006), 'MAC protocols for wireless sensor networks: A survey', *IEEE Communications Magazine* **44**(4), 115–121.
- Dendronautics (2007), 'Dendronautics'. URL <http://www.dendronautics.org>.
- Dong, M., Tong, L. & Sadler, B. M. (2006), 'Impact of data retrieval pattern on homogeneous signal field reconstruction in dense sensor networks', *IEEE Transactions on Signal Processing* **54**(11), 4352–4364.
- Eclipse CDT Project (2006), 'C/C++ development tools'. URL <http://www.eclipse.org/cdt>.
- Eclipse Project (2006), 'Eclipse SDK'. URL <http://www.eclipse.org>.
- Ehrlich, C., Papamichael, K., Lai, J. & Revzan, K. (2001), Simulating the operation of photosensor-based lighting controls, in 'Proceedings of the Seventh International IBPSA Conference', Rio de Janeiro, pp. 857–864.
- Engelbrecht, B. M. J. & Herz, H. M. (2001), 'Evaluation of different methods to estimate understorey light conditions in tropical forests', *Journal of Tropical Ecology* **17**, 207–224.
- Faizulkhakov, Y. R. (2007), 'Time synchronization methods for wireless sensor networks: A survey', *Programming and Computer Software* **33**(4), 214–226.
- Fasolo, E., Rossi, M., Widmer, J. & Zorzi, M. (2007), 'In-network aggregation techniques for wireless sensor networks: A survey', *IEEE Wireless Communications* **14**(2), 70–87.
- Frery, A. C., Ramos, H., Alencar-Neto, J. & Nakamura, E. F. (2008), Error estimation in wireless sensor networks, in 'ACM Symposium on Applied Computing', ACM, Fortaleza, CE, Brazil, pp. 1923–1927.
- GNU Project (2007), 'GNU C Compiler'. URL <http://www.gnu.org>.
- Grinstead, C. M. & Snell, J. L. (1997), *Introduction to Probability*, 2 ed., American Mathematical Society.
- Heidemann, J., Ye, W., Wills, J., Syed, A. & Li, Y. (2006), Research challenges and applications for underwater sensor networking, in 'Wireless Communications and Networking Conference – WCNC', Vol. 1, IEEE, pp. 228–235.
- Heinzelman, W. B., Chandrakasan, A. P. & Balakrishnan, H. (2002), 'An application-specific protocol architecture for wireless microsensor networks', *IEEE Transactions on Wireless Communications* **1**(4), 660–670.
- Heinzelman, W. R., Chandrakasan, A. & Balakrishnan, H. (2000), Energy-efficient communication protocol for wireless microsensor networks, in 'Proceedings of the Hawaii International Conference on System Sciences', Massachusetts Institute of Technology, Cambridge, United States of America, pp. 157–165.
- Jennings, S. B., Brown, N. D. & Sheil, D. (1999), 'Assessing forest canopies and understorey illumination: canopy closure, canopy cover and other measures', *Forestry* **72**(1), 59–73.
- Jiang, X., Polastre, J. & Culler, D. (2005), Perpetual environmentally powered sensor networks, in 'IPSN '05: Proceedings of the 4th International Symposium on Information Processing in Sensor Networks', IEEE Press, Piscataway, NJ, USA, p. 65.
- Jindal, A. & Psounis, K. (2004), 'Modeling spatially-correlated sensor network data', *IEEE Communications Society Conference on Sensor and Ad Hoc Communications and Networks*.
- Kalpakis, K., Dasgupta, K. & Namjoshi, P. (2003), 'Efficient algorithms for maximum lifetime data gathering and aggregation in wireless sensor networks', *Computer Networks-The International Journal of Computer and Telecommunications Networking* **42**(6), 697–716.
- Karlin, S. & Taylor, H. M. (1975), *A First Course in Stochastic Processes*, Academic, New York.

- Krzanowski, W. J. (1988), *Principles of Multivariate Analysis: a User's Perspective*, Oxford Statistical Science Series, Clarendon Press, Oxford.
- Levis, P., Lee, N., Welsh, M. & Culler, D. (2003), 'TOSSIM: Accurate and scalable simulation of entire tinyOS applications', *ACM Conference on Embedded Networked Sensor Systems* pp. 126–137.
- Luo, H., Liu, Y. & Das, S. (2007), 'Routing correlated data in wireless sensor networks: A survey', *IEEE Network* **21**(6), 40–47.
- Machado, M. V., Goussevskaia, O., Mini, R. A. F., Rezende, C. G., Loureiro, A. A. F., Mateus, G. R. & Nogueira, J. M. S. (2005), 'Data dissemination in autonomic wireless sensor networks', *IEEE Journal on Selected Areas in Communications* **23**(1-3), 2305–2319.
- McHenry, S. T. & Heidemann, J. (2007), MAC stability in sensor networks at high network densities, Technical Report ISI-TR-628, Information Sciences Institute, University of Southern California.
- Mhatre, V. P., Rosenberg, C., Kofman, D., Mazumdar, R. & Shroff, N. (2005), 'A minimum cost heterogeneous sensor network with a lifetime constraint', *IEEE Transactions on Mobile Computing* **4**(1), 4–15.
- Mini, R. A. F., Nath, B. & Loureiro, A. A. F. (2002), A probabilistic approach to predict the energy consumption in wireless sensor networks, in 'IV Workshop de Comunicação Sem Fio', São Paulo, SP, pp. 232–245.
- Muirhead, R. J. (1982), *Aspects of Multivariate Statistical Theory*, Wiley Series in Probability and Mathematical Statistics, Wiley, New York.
- Nakamura, E. F., Loureiro, A. A. F. & Frery, A. C. (2007), 'Information fusion for wireless sensor networks: Methods, models, and classifications', *ACM Computing Surveys* **39**, 1–55.
- Nakamura, E. F., Nakamura, F. G., Figueiredo, C. M. S. & Loureiro, A. A. F. (2005), 'Using information fusion to assist data dissemination in wireless sensor networks', *Telecommunication Systems* **30**(1-3), 237–254.
- Nowak, R., Mitra, U. & Willett, R. (2004), 'Estimating inhomogeneous fields using wireless sensor networks', *IEEE Journal on Selected Areas in Communications* **22**(6), 999–1006.
- Okabe, A., Boots, B. & Sugihara, K. (1992), *Spatial Tessellations: Concepts and Applications of Voronoi Diagrams*, John Wiley and Sons.
- Palit, S. (1997), 'Signal extraction from multiple noisy sensors', *Signal Processing* **61**(3), 199–212.
- Paradis, L. & Han, Q. (2007), 'A survey of fault management in wireless sensor networks', *Journal of Network and Systems Management* **15**(2), 171–190.
- Pebesma, E. J. & Bivand, R. S. (2005), 'Classes and methods for spatial data in R', *R News* **5**(2), 9–13. URL <http://CRAN.R-project.org/doc/Rnews/>.
- Pompili, D., Melodia, T. & Akyildiz, I. F. (2006), 'Deployment analysis in underwater acoustic wireless sensor networks', pp. 48–55.
- R Development Core Team (2006), 'R: A language and environment for statistical computing'. URL <http://www.R-project.org>, ISBN 3-900051-07-0.
- Reis, I. A., Câmara, G., Assunção, R. & Monteiro, A. M. V. (2007), Data-aware clustering for geosensor networks data collection, in 'Anais XIII Simpósio Brasileiro de Sensoriamento Remoto', Florianópolis, SC, Brazil, pp. 6059–6066. URL <http://www.dsr.inpe.br/sbsr2007/biblioteca>.
- Sadler, B. M. (2005), 'Fundamentals of energy-constrained sensor network systems', *IEEE Aerospace and Electronic Systems Magazine* **20**(8), 17–35.
- Schlather, M. (1999), Introduction to positive definite functions and to unconditional simulation of random fields, Technical Report ST-99-10, Department of Mathematics and Statistics, Lancaster University, UK.

- Schlather, M. (n.d.), *RandomFields: Simulation and Analysis of Random Fields*. URL [http://www.stochastik.math.uni-goettingen.de/institute/index.php?page\\_to\\_show=personen](http://www.stochastik.math.uni-goettingen.de/institute/index.php?page_to_show=personen), R package version 1.3.30.
- Tan, H. O. & Korpeoglu, I. (2003), 'Power efficient data gathering and aggregation in wireless sensor networks', *Sigmod Record* **32**(4), 66–71.
- Thompson Reuters (2007), 'ISI Web of Knowledge'. URL <http://isiwebofknowledge.com>.
- Tong, Y. L. (1990), *The Multivariate Normal Distribution*, Springer Series in Statistics, Springer-Verlag, New York.
- Turner, R. (2007), *deldir: Delaunay Triangulation and Dirichlet (Voronoi) Tessellation*. URL <http://www.math.unb.ca/~rolf/>, R package version 0.0-7.
- Velho, L., Miranda, J. & Frery, A. C. (2008), *Image Processing for Computer Graphics and Vision*, Springer.
- Wang, C. G., Sohraby, K., Li, B., Daneshmand, M. & Hu, Y. M. (2006a), 'A survey of transport protocols for wireless sensor networks', *IEEE Network* **20**(3), 34–40.
- Wang, G. L., Cao, G. H. & Porta, T. F. L. (2006b), 'Movement-assisted sensor deployment', *IEEE Transactions on Mobile Computing* **5**(6), 640–652.
- Ye, W. & Heidemann, J. (2006), 'Ultra-low duty cycle MAC with scheduled channel polling'. URL <http://citeseer.ist.psu.edu/ye06ultralow.html>.
- Ye, W., Heidemann, J. & Estrin, D. (2004), 'Medium access control with coordinated adaptive sleeping for wireless sensor networks', *IEEE-ACM Transactions on Networking* **12**(3), 493–506.
- Yoon, S. & Shahabi, C. (2007), 'The Clustered AGgregation (CAG) technique leveraging spatial and temporal correlations in wireless sensor networks', *ACM Transactions on Sensor Networks* **3**(1), 3/1–39.
- Younis, O. & Fahmy, S. (2004), 'HEED: A hybrid, energy-efficient, distributed clustering approach for ad hoc sensor networks', *IEEE Transactions on Mobile Computing* **3**(4), 366–379.
- Zhao, Q. & Tong, L. (2007), 'Energy-efficient information retrieval for correlated source reconstruction in sensor networks', *IEEE Transactions on Wireless Communications* **6**(1), 157–165.
- Zhao, Q., Swami, A. & Tong, L. (2006), 'The interplay between signal processing and networking in sensor networks - a perspective on large-scale networks for military applications', *IEEE Signal Processing Magazine* **23**(4), 84–93.

Este documento foi preparado utilizando L<sup>A</sup>T<sub>E</sub>X.  
As referências bibliográficas foram administradas com B<sub>I</sub>B<sub>T</sub>E<sub>X</sub>.  
O fonte do texto é Beton e o das equações Euler e Eucal, em 12 pontos.

