



UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Botucatu



AIRA NAVA

**VARIABILIDADE ESPACIAL DE NÍVEIS FREÁTICOS DO SISTEMA AQUÍFERO
BAURU POR MEIO DE MODELO HÍBRIDO MULTIVARIADO**

**Botucatu
2018**

AIRA NAVA

**VARIABILIDADE ESPACIAL DE NÍVEIS FREÁTICOS DO SISTEMA AQUÍFERO
BAURU POR MEIO DE MODELO HÍBRIDO MULTIVARIADO**

Tese apresentada à Faculdade de Ciências Agronômicas da Unesp Câmpus de Botucatu, para obtenção do título Doutora em Agronomia (Irrigação e Drenagem).

Orientador: Prof. Dr. Rodrigo Lilla
Manziane

Botucatu

2018

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO DA INFORMAÇÃO - DIRETORIA TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO - UNESP - FCA - LAGEADO - BOTUCATU (SP)

N316v Nava, Aira, 1988-
Variabilidade espacial de níveis freáticos do Sistema Aquífero Bauru por meio de modelo hídrico multivariado / Aira Nava. - Botucatu : [s.n.], 2018
112 p.: il. color, tabs.

Tese(Doutorado)- Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas, Botucatu, 2018
Orientador: Rodrigo Lilla Manzione
Inclui bibliografia

1. Águas subterrâneas. 2. Geologia - Métodos estatísticos. 3. Regressão linear múltipla. 4. Krigagem. I. Manzione, Rodrigo Lilla. II. Universidade Estadual Paulista "Júlio de Mesquita Filho" (Câmpus de Botucatu). Faculdade de Ciências Agrônômicas. III. Título.

Ficha elaborada por : Maria Lúcia Martins Frederico - CRB-8:5255

Permitida a cópia total ou parcial deste documento, desde que citada a fonte"

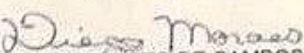
CERTIFICADO DE APROVAÇÃO

Título: "MODELAGEM ESPACIAL DE NÍVEIS FREÁTICOS NO SISTEMA
AQUÍFERO BAURU UTILIZANDO MODELO HÍBRIDO
MULTIVARIADO"


AUTORA: AIRA NAVA
ORIENTADOR: RODRIGO LILLA MANZIONE

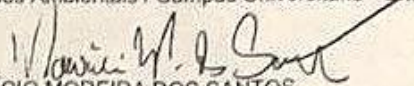
Aprovada como parte das exigências para obtenção do Título de Doutora em AGRONOMIA
(IRRIGAÇÃO E DRENAGEM), pela Comissão Examinadora:


Prof. Dr. RODRIGO LILLA MANZIONE
/ Faculdade de Ciências e Engenharia - UNESP - Tupã/SP


Prof. Dr. DIEGO AUGUSTO DE CAMPOS MORAES
Análise e Desenvolvimento de Sistemas / Faculdade Eduvale de Avaré


Dr. MARIA MARCIA PEREIRA SARTORI
Produção e Melhoramento Vegetal / Faculdade de Ciências Agrônômicas - UNESP


Prof. Dr. DIDIER GASTMANS
Centro de Estudos Ambientais / Campus Universitário - Unesp - Rio Claro/SP


Prof. Dr. MAURÍCIO MOREIRA DOS SANTOS
Engenharia Ambiental / Universidade Tecnológica Federal do Paraná

Botucatu, 25 de setembro de 2018.

Aos meus pais, Agnes e Antônio, e aos meus avós,
Cacilda e Gumercindo, com muito amor,
dedico.

AGRADECIMENTOS

À minha família, pelo apoio incondicional e pela compreensão por esses anos longe de casa.

À minha mãe, pelo amor e paciência e por ser minha companheira de vida.

Ao prof. Rodrigo L. Manzione, pelas oportunidades e pelos vários anos de estrada junto comigo.

À prof. Célia Regina L. Zimback, meus agradecimentos e admiração, por ter me ouvido, confiado e acreditado no momento em que eu mais precisei.

Aos profs. Luís Gustavo F. Lessa, Diego Augusto C. Moares e Anderson Antônio C. Sartori, pelo companheirismo no GEPAG e por estarem presentes nessa etapa final da minha formação.

À prof. Maria Márcia P. Sartori, pela enorme paciência e simpatia e por me ensinar a colocar em prática os conhecimentos estatísticos adquiridos ao longo do tempo.

À Andressa N. Costa, amiga e professora, por se dispor a me ajudar e por me dar forças para continuar traçando meu caminho acadêmico.

Aos membros da banca por aceitarem o convite. Agradeço pela educação e disposição.

Ao Bruno, por estar sempre comigo, dividindo as alegrias e angustias. Ao sr. Alberto Calderón, por todo amor, apoio e empolgação que nos foi dado.

Aos meus amigos, por compartilharem todos os momentos vividos em Botucatu. À Flávia e ao Pedro, pelas horas de risadas e de filosofia sobre a vida. À Joyce, pelas boas conversas ao longo desses anos. À Michele e ao Johnny, que mesmo distantes, sempre estiveram comigo. Aos amigos do grupo GEPAG, por todo conhecimento produzido e compartilhado, em especial ao Lucas, Donizeti, Ana Paula e Mirian.

Portaria CAPES 206/2018:

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

“Um poder que se serve, em vez de servir, é um poder que não serve”.
Mario Sergio Cortella

RESUMO

A geoestatística permite inferir valores desconhecidos que apresentam estrutura espacial, auxiliando, assim, na descrição dos fenômenos naturais. A utilização de seus interpoladores permite um melhor entendimento do objeto de estudo, pois seu embasamento matemático garante a confiabilidade do método e sua utilização associada ao entendimento físico do problema proporciona resultados significativos. As ferramentas geoestatísticas vem sendo amplamente utilizadas no monitoramento e nos estudos dos recursos hídricos. Partindo-se da hipótese de que os níveis de água subterrânea podem ser explicados por um modelo determinístico e espacializados por ferramentas da geoestatística, o trabalho teve como objetivo o mapeamento do lençol freático através de um modelo híbrido de regressão-krigagem. Dados relacionados ao relevo, ao solo, às series de monitoramento da água e à vegetação, obtidos por sensoriamento remoto, totalizaram 21 variáveis preditivas dos níveis do lençol freático. As informações sobre as águas subterrâneas foram coletadas por meio de 56 piezômetros e as informações sobre os solos foram coletadas em 113 pontos amostrais distribuídos irregularmente nas bacias hidrográficas dos rios Guarantã, Bugre, Boi, Santana e Passarinho. A seleção das variáveis de maior relevância para o ajuste do modelo de regressão linear foi realizada por meio da análise de componentes principais, que determinou aquelas com maior variabilidade. Os resultados mostraram robusto ajuste aos dados pelo modelo e robusta capacidade preditiva para novas observações. O ajuste dos variogramas permitiu a krigagem ordinária dos níveis freáticos médios e dos resíduos do modelo determinístico, possibilitando um mapa final de predição das águas subterrâneas.

Palavras-chave: águas subterrâneas, geoestatística, regressão linear múltipla, regressão-krigagem.

ABSTRACT

Geostatistics allows inferring unknown values with spatial structure, supporting the natural phenomena description. Geostatistical interpolators increase the understanding about the studied object, since its mathematical background ensures reliability to the method and its use associated to the physical understanding of the problem provides significant results. Geostatistical tools have been widely used in groundwater monitoring and studies. From the hypothesis that groundwater levels can be explained by a deterministic model and spatialized with geostatistics, this work aimed to map the water table through a hybrid regression-kriging model. Soil, topographic, water and vegetation monitoring data (obtained by remote sensing) were used as predictive variables of groundwater levels. Information were collected at Guarantã, Bugre, Boi, Santana and Passarinho watersheds. The most relevant variables for the multiple regression model were chosen through principal components analysis, which determined those with greater variability. The results indicated a robust fit to the data by the model and robust predictive capacity for new observations. The adjustment of the variograms allowed the ordinary kriging of the mean water levels and the residuals of the deterministic model, allowing a final prediction map of the groundwater.

Keywords: groundwater, geostatistics, multiple linear regression, regression-kriging.

LISTA DE FIGURAS

Figura 1 - Questões associadas às águas subterrâneas e os setores políticos relacionados.....	24
Figura 2 - Representação esquemática da distribuição vertical da água no solo, mostrando as diferentes zonas de umidade.....	27
Figura 3 - Representação esquemática de um sistema de fluxo de água subterrânea.....	29
Figura 4 - Classificação de dados geográficos com base no modelo de dados.....	33
Figura 5 - Camadas de informações gerenciadas pelo SIG.....	34
Figura 6 - Abordagens usadas para representar o mundo real.....	35
Figura 7 - Fluxo de trabalho de informações representando o acoplamento de modelos de sensoriamento remoto, SIG e bacias hidrográficas.....	36
Figura 8 - Sistema de coordenadas X1 e X2, novo sistema Y1 e Y2, ângulos de rotação dos novos eixos e autovalores.....	38
Figura 9 - Representação gráfica de um semivariograma.....	42
Figura 10 - Representação do ajuste espacial de uma variável ambiental através da regressão-krigagem.....	47
Figura 11 - Processo de modelagem por RK.....	47
Figura 12 - Localização da EEcSB e da FESB no município de Águas de Santa Bárbara – SP.....	50
Figura 13 - Área de estudos com a rede de drenagem da EEcSB e FESB.....	52
Figura 14 - Altimetria das bacias hidrográficas da EEcSB e da FESB.....	53
Figura 15 - Formações geológicas da região da EEcSB e FESB.....	54
Figura 16 - Mapa de solos na região da EEcSB e FESB.....	55
Figura 17 - Localização dos poços de monitoramento das águas subterrâneas.....	56
Figura 18 - Localização dos pontos amostrais de solo na EEcSB e FESB.....	58
Figura 19 - Árvore de decisão para a seleção do modelo de predição espacial.....	60

Figura 20 - Estrutura para o mapeamento digital dos níveis freáticos com base na regressão-krigagem.....	67
Figura 21 - Modelo Digital de Elevação da área de estudo.....	68
Figura 22 - Declividade (%) da área de estudo.....	69
Figura 23 - Índice Topográfico de Umidade (ITU) para área de estudos.....	70
Figura 24 - Índice de Vegetação por Diferença Normalizada (NDVI) para a área de estudo.....	72
Figura 25 - Índice de Vegetação Realçado (EVI 2) para área de estudo.....	73
Figura 26 - Índice de Vegetação Ajustado ao Solo (SAVI) para área de estudo.....	74
Figura 27 - Índice de Umidade por Diferença Normalizada (NDWI) para área de estudo.....	75
Figura 28 - Avaliação do modelo de predição dos níveis freáticos.....	81
Figura 29 - Comparação entre os dados observados e os dados estimados pelo modelo.....	82
Figura 30 - Semivariograma estável isotrópico para a estimativa dos níveis freáticos médios.....	84
Figura 31 - Semivariograma gaussiano isotrópico para a estimativa dos resíduos da RLM.....	84
Figura 32 - Mapa de interpolação por krigagem ordinária dos níveis freáticos médios.....	86
Figura 33 - Mapa de interpolação por krigagem ordinária dos resíduos dos níveis freáticos médios.....	87
Figura 34 - Mapa de interpolação por krigagem ordinária do desvio-padrão níveis freáticos médios estimados.....	88
Figura 35 - Mapa de interpolação por krigagem ordinária do desvio-padrão resíduos dos níveis freáticos médios.....	89
Figura 36 - Mapa final dos níveis freáticos médios elaborado por meio do modelo de regressão-krigagem.....	90

LISTA DE TABELAS

Tabela 1 - Estatística descritiva dos dados.....	77
Tabela 2 - Autovetores calculados para as primeiras cinco componentes principais (PC) obtidas a partir da PCA.....	79
Tabela 3 - Valores de significância das variáveis preditoras.....	80
Tabela 4 - Modelos e parâmetros dos semivariogramas isotrópicos ajustados aos níveis médios do lençol freático e aos resíduos estimados na regressão linear múltipla.....	83
Tabela 5 - Estatísticas da validação para os semivariogramas ajustados.....	85

SUMÁRIO

1	INTRODUÇÃO.....	21
2	REVISÃO DE LITERATURA.....	23
2.1	Pesquisas sobre as águas subterrâneas para a gestão dos recursos hídricos.....	23
2.1.1	Geotecnologias empregadas nos estudos de águas subterrâneas.....	25
2.2	Águas Subterrâneas.....	27
2.2.1	Variáveis ambientais que influenciam nos níveis de água subterrânea.....	30
2.3	Modelagem dos recursos hídricos em SIG.....	32
2.4	Modelagem multivariada de dados.....	36
2.4.1	Análise de Componentes Principais (PCA).....	37
2.5	Modelagem espacial de dados geográficos.....	39
2.5.1	Variabilidade espacial dos dados.....	39
2.5.2	Interpolação geoestatística – Krigagem.....	42
2.5.2.1	<i>Krigagem Ordinária.....</i>	<i>43</i>
2.5.3	Regressão-krigagem.....	44
3	MATERIAL E MÉTODOS.....	50
3.1	Caracterização da área de estudos.....	51
3.1.1	Sistema Aquífero Bauru (SAB).....	56
3.2	Poços de monitoramento das águas subterrâneas.....	57
3.3	Material.....	58
3.3.1	Base cartográfica.....	58
3.3.2	Imagens Orbitais.....	59
3.3.3	Amostragem de solo.....	59
3.3.4	Programas.....	60
3.4	Métodos.....	61
3.4.1	Índices utilizados.....	61
3.4.2	Obtenção do Modelo Digital de Elevação (MDE) e da declividade.....	64
3.4.3	Análise de componentes principais e modelo de regressão linear múltiplo.....	65
3.4.4	Ajuste do modelo de predição e avaliação do semivariograma.....	65

3.4.5	Elaboração do modelo de regressão-krigagem.....	66
4	RESULTADOS E DISCUSSÃO.....	68
4.1	Levantamento de variáveis ambientais.....	68
4.1.1	Variáveis do terreno.....	68
4.1.2	Variáveis da vegetação.....	71
4.1.3	Variáveis relacionadas ao solo.....	76
4.2	Análise exploratória dos dados.....	77
4.3	Análise de componentes principais.....	78
4.4	Ajuste do modelo determinístico para estimativa do nível médio do lençol freático.....	80
4.5	Modelagem da estrutura de variabilidade espacial.....	83
4.6	Mapeamento da água subterrânea.....	85
5	CONCLUSÕES.....	92
6	CONSIDERAÇÕES FINAIS.....	93
	REFERÊNCIAS.....	95
	APÊNDICE.....	107

1 INTRODUÇÃO

Fundamental para o desenvolvimento humano e para a sustentação dos ecossistemas, a água subterrânea é um dos recursos mais valiosos do planeta. Fonte de abastecimento para grande parte da população, esse recurso apresenta funções de extrema importância, tais como armazenamento, filtragem e de energia por meio do seu gradiente geotermal. Atua sobre os ciclos hidrológicos, atmosféricos e de nutrientes, servindo, por exemplo, como sumidouro no ciclo do carbono.

Apesar disso, o recurso vem sofrendo com o aumento da demanda por água pela população e com a poluição resultante das diversas atividades econômicas, além dos efeitos das mudanças climáticas. O impacto combinado desses fatores pode afetar substancialmente o equilíbrio hidrológico, uma vez que a transformação do meio natural altera variáveis importantes como as taxas de interceptação, de infiltração e de evapotranspiração, resultando no declínio da recarga e dos níveis de água subterrânea, bem como na degradação de sua qualidade.

Nesse sentido, o monitoramento e as pesquisas relacionadas às águas subterrâneas são fundamentais para gestão dos recursos hídricos. A aplicação de modelos hidrológicos aos dados permite um maior entendimento dos processos envolvidos e a criação de cenários que servem para diagnosticar as condições desses recursos.

Os sistemas de águas subterrâneas são complexos e heterogêneos. Seus níveis são afetados por combinações de vários fatores naturais e antropogênicos, como precipitação, geologia, declividade e retirada de água. Esses fatores aliados as características inerentes (permeabilidade, transmissividade, temperatura, vulnerabilidade, entre outras) representam desafios para modelagem.

A geoestatística vem sendo amplamente utilizada como ferramenta para o planejamento dos recursos naturais, pois permite a modelagem da dispersão espacial das grandezas que os definem. Por meio de seus instrumentos, é possível prever um determinado valor de uma variável e quantificar a incerteza ligada ao fenômeno espacial.

Os dados obtidos por meio dos estudos e das pesquisas quando são utilizados em conjunto com interpoladores e modelos geoestatísticos podem permitir melhor caracterização e entendimento do fenômeno estudado. A geoestatística representa, então, uma ferramenta confiável para a estimativa dos fenômenos naturais, pois seu

embasamento matemático garante a confiabilidade do método e sua utilização associada ao entendimento físico do problema proporciona resultados robustos (VICENTE, 2004; GIACOMIN et al., 2014).

A compreensão de fenômenos naturais exige, assim, a utilização de ferramentas matemáticas avançadas para diversas finalidades, tais como: desenvolvimento de processos, otimização, controle, classificação, *clustering* e predição. Os modelos geoestatísticos híbridos são de importância significativa, pois combinam o significado físico do modelo determinístico com a capacidade de redução de complexidade dos modelos estocásticos para aprimorar a estratégia de modelagem, enquanto uma precisão desejada é direcionada (ZENDEHBOUDI et al., 2018).

A Regressão-krigagem (RK) é uma ferramenta híbrida da geoestatística que corresponde à combinação da regressão multivariada com a krigagem ordinária. A ferramenta considera a autocorrelação espacial da variável de interesse, a correlação entre a variável de interesse e variáveis auxiliares (por exemplo, imagens de sensoriamento remoto são relativamente fáceis de obter como variáveis auxiliares) e a estimativa espacial não-tendenciosa com variância minimizada (MENG et al. 2013).

As informações acerca dos níveis de água subterrânea são obtidas por meio piezômetros distribuídos pela área de interesse, onde os espaçamentos dependem de fatores como custo de perfuração e irregularidade do terreno. A variável nível de água subterrânea representa uma variável regionalizada pela qual podem ser gerados modelos de blocos ou malhas de pontos para a elaboração de mapas de nível. Tem-se, então, com a geoestatística, uma forma de descrever a sua continuidade espacial, inclusive em locais onde a variável não foi amostrada (BOEZIO et al., 2006).

A partir desses pressupostos, este trabalho teve como hipótese que a espacialização dos níveis freáticos pode ser feita por meio da aplicação de um modelo geoestatístico híbrido multivariado. E teve como objetivo compreender o comportamento espacial das águas subterrâneas que se encontram em uma Área de Proteção Ambiental sobre o Sistema Aquífero Bauru (SAB) sob diferentes influências.

Buscou-se, como objetivos específicos: i) elaborar um banco de dados digital das águas subterrâneas do SAB com base nas informações coletadas do local de estudos; ii) verificar a viabilidade do emprego de imagens orbitais como meio de extrair variáveis explicativas dos níveis de lençol freático; iii) elaborar o mapeamento digital das águas subterrâneas.

2 REVISÃO DE LITERATURA

2.1 Pesquisas sobre as águas subterrâneas para a gestão dos recursos hídricos

Mudanças na disponibilidade de recursos hídricos apresentam impactos no meio ambiente. A relação existente entre os corpos hídricos superficiais e as águas subterrâneas é de fundamental importância no entendimento do ciclo hidrológico. Em grande parte do território brasileiro, o fluxo de base proveniente dos aquíferos alimenta os rios e os mantém perenes nos períodos secos. Para entender relações como esta, é necessário caracterizar a resposta dos aquíferos em função das variáveis climáticas que influenciam o sistema, das características hidrogeológicas locais e do uso e ocupação da terra (MANZIONE, 2015).

Os estudos em hidrologia se tornam cada vez mais importantes à medida que há o aumento da demanda sobre um estoque de água limitado. Para proteger os recursos e, ao mesmo tempo, atender a essa necessidade crescente, deve-se saber onde encontrar água e, também, como seus estoques se renovam. Por meio deste conhecimento, é possível dispor do recurso sem comprometer o abastecimento futuro (COLERIDGE, 2008).

O monitoramento das águas subterrâneas fornece dados importantes ao planejamento dos recursos hídricos, possibilitando indicações a respeito de mudanças que estejam ocorrendo como consequência de práticas de manejo. (RENNÓ; SOARES, 2000).

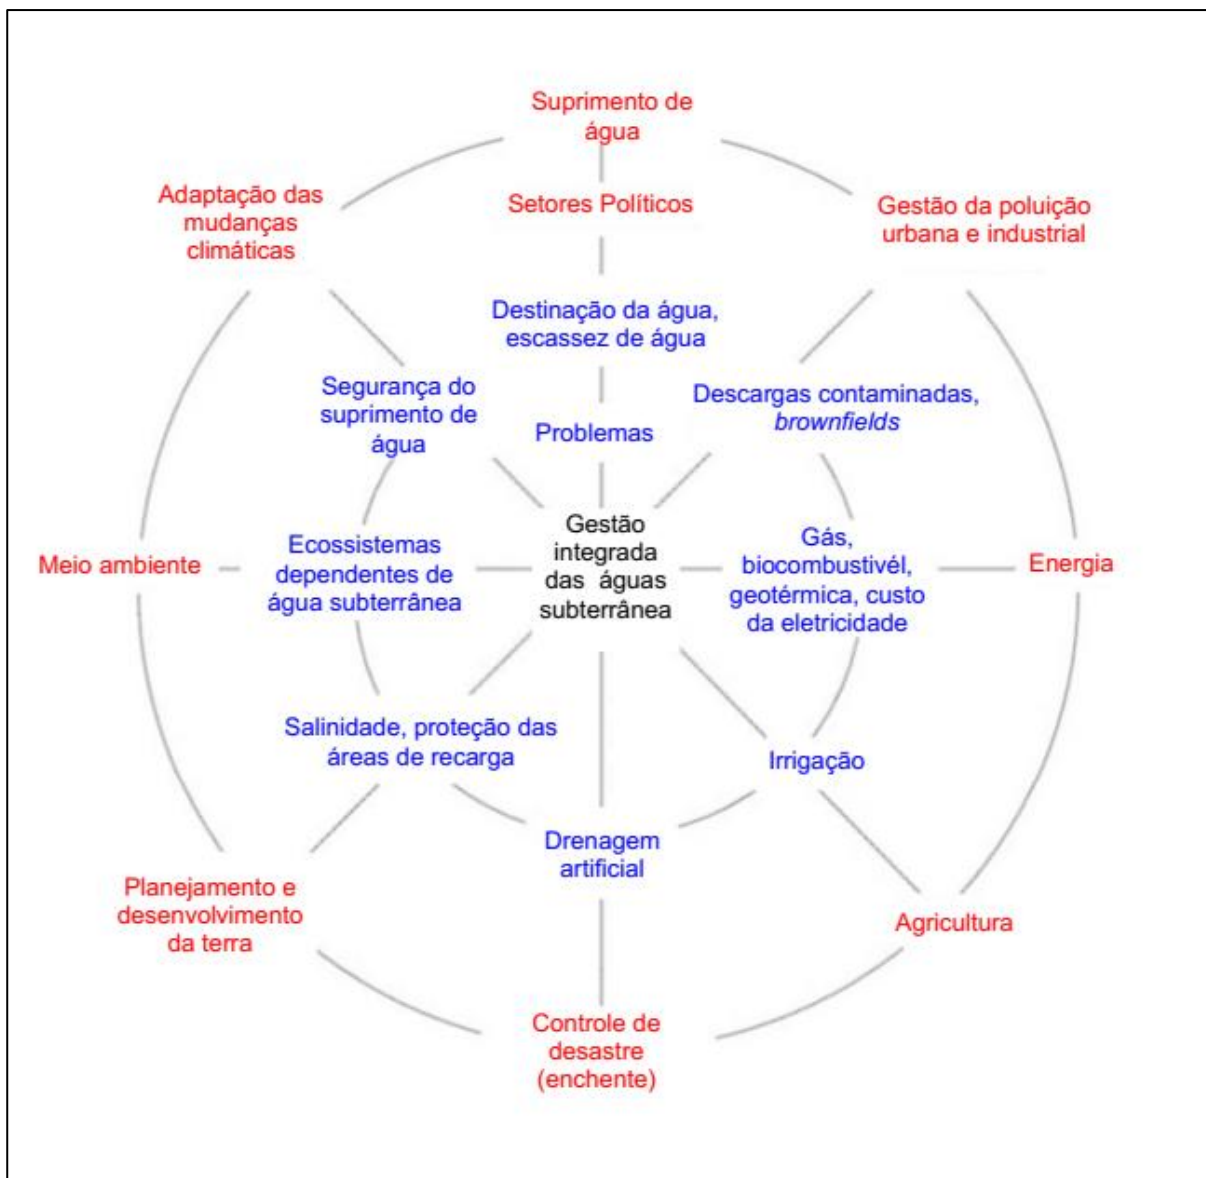
Nesse sentido, a gestão dos recursos hídricos é essencial, uma vez que se caracteriza como o conjunto de ações a fim de regular o uso, o controle e a proteção desses recursos em conformidade com a legislação e normas pertinentes (IBGE, 2013). De acordo com Dias et al. (2008), a Política Nacional de Recursos Hídricos conceitua a importância da gestão sistemática dos recursos hídricos sem a dissociação dos aspectos de quantidade e de qualidade, conforme o enunciado do Art. 3º, Cap. III, Tit. I, Lei nº 9.433.

Para Hirata et al. (2010), a gestão da água subterrânea no país ainda precisa avançar e a falta de políticas públicas para o setor reflete uma lacuna de conhecimento do estágio de utilização e das potencialidades dos aquíferos. Para os autores, os desafios enfrentados para a gestão envolvem a regulamentação do uso da água subterrânea, a avaliação dos riscos aos quais estão submetidas e a determinação de

bases técnicas que viabilizam aproveitar, de forma integrada e sinérgica, os recursos hídricos superficiais e subterrâneos.

Dessa forma, uma gestão integrada das águas subterrâneas é necessária, pois se configura como um processo estruturado que promove o manejo coordenado com os demais recursos e que considera as relações políticas envolvidas, visando alcançar o equilíbrio econômico, social e ambiental a longo prazo (JAKEMAN et al., 2016), Figura 1.

Figura 1 - Questões associadas às águas subterrâneas e os setores políticos relacionados



Fonte: JAKEMAN et al. (2016).

Assim, para que as informações reunidas pelas redes de monitoramento sejam plenamente utilizadas é preciso testar metodologias que acessem a variabilidade espacial e temporal dos dados de maneira conjunta, o que continua sendo um desafio (VON ASMUTH; KNOTTERS, 2004).

2.1.1 Geotecnologias empregadas nos estudos de águas subterrâneas

Geotecnologias representam um conjunto de tecnologias para coleta, processamento, análise e fornecimento de informações geograficamente referenciadas. Em um país de tamanha extensão como Brasil, onde há a necessidade de expandir os conhecimentos afim de tomar decisões perante aos problemas urbanos, ambientais e rurais, tais ferramentas se mostram promissoras, pois permitem que informações sejam adquiridas localmente a um custo relativamente baixo (TEIXEIRA, 2015).

O geoprocessamento, ao envolver técnicas e conceitos de cartografia, sensoriamento remoto e Sistemas de Informações Geográficas (SIG), vem sendo empregado com êxito no controle e monitoramento ambiental (PEREIRA et al. 2014). Nesse contexto, sensoriamento remoto é um instrumento bastante útil, pois proporciona uma análise integrada de grandes áreas e permite que regiões de difícil acesso possam ser trabalhadas. Por isso, a geologia, incluindo a área da hidrogeologia, está entre as ciências que se beneficiam deste tipo de produto (LEITE et al., 2013).

As técnicas de sensoriamento remoto se fundamentam em um processo de interação entre a radiação eletromagnética e os diferentes objetos de estudo. O sensoriamento remoto é definido como um método de aquisição de informações sobre os fenômenos e os objetos que compõem a superfície terrestre sem a necessidade de contato direto com os mesmos. A quantidade de energia eletromagnética refletida e emitida pelos alvos terrestres é resultado das interações entre ambos. Essas interações são influenciadas pelas propriedades físicas, químicas e biológicas desses alvos e podem ser identificadas nas imagens e nos dados de sensores remotos, o que permite avaliar suas principais características (MORAES, 2008).

A aplicação dessas técnicas é viabilizada com o cumprimento de diversas etapas que incluem a interação em si (caracterizada pelo fenômeno de reflexão da radiação), a coleta de dados e seu registro por um sensor e a análise desses dados com o

objetivo de extrair as informações pretendidas de um dado objeto (PONZONI; SANTOS, 2008).

O sensoriamento remoto estuda os recursos hídricos por meio de dados espectrais da energia eletromagnética, emitida ou refletida, nas faixas de comprimento de onda desde $0,3 \mu\text{m}$ até as microondas. O monitoramento da água subterrânea por meio de sensoriamento remoto é um desafio, pois sua aplicação é feita com base em interpretações dos dados que registram os fenômenos da superfície. Neste caso, a água subterrânea é inferida com base em indicadores, como fisionomia e estrutura geológica da superfície, distribuição e tipos de vegetação, umidade dos solos, presença de rios e nascentes, entre outros. O processamento dos dados digitais de várias bandas e a análise da imagem pelo reconhecimento de padrões, agrupamentos e classificações são essenciais para localizar e entender as águas subterrâneas (LIU, 2006).

Segundo Jensen (2009), uma quantidade significativa de pesquisas tem sido feita para desenvolver técnicas de sensoriamento remoto que possibilitam obter medidas espaciais quantitativas de importantes variáveis hidrológicas, tais como precipitação, cobertura de nuvens, profundidade da água (batimetria), área da superfície, entre outras. Atualmente, modelos específicos de SIG podem ser construídos para monitorar este recurso. Desta forma, as informações da área de interesse são indispensáveis para validação dos métodos empregados nas interpretações (LIU, 2006).


Concisamente, de acordo com Veiga e Silva (2004), os SIGs podem ser definidos como ferramentas computacionais que manipulam objetos (feições geográficas) e seus atributos (registros que integram um banco de dados) por meio de seu relacionamento espacial (topologia). Empregar um SIG no monitoramento do meio ambiente permite realizar análises complexas do local de estudos ao integrar dados de diversas fontes, ao criar bancos de dados georreferenciados e ao possibilitar o cruzamento das informações e imagens armazenadas (OLIVEIRA et al. 2008; TEIXEIRA, 2015).

Dessa forma, as técnicas de geoprocessamento são instrumentos fundamentais para a manutenção de registros do uso da terra, permitindo avaliar as mudanças ocorridas na paisagem de uma região ao longo do tempo (CAMPOS et al. 2004).

2.2 Águas Subterrâneas

A água subterrânea é aquela que circula abaixo da superfície do terreno, nas fraturas e nos poros existentes entre as partículas não consolidadas que formam os solos e as rochas sedimentares e magmáticas. Seu processo de formação ocorre quando, ao infiltrar no solo, a água passa por uma camada chamada de zona não saturada, na qual os poros são preenchidos tanto por água quanto por ar. Parte desta água é absorvida pelas raízes das plantas, por outros organismos vivos ou evapora, e o restante continua em movimento descendente devido à ação da gravidade, acumulando-se nas zonas mais profundas e preenchendo totalmente os poros, formando a zona saturada (IRITANI; EZAKI, 2012), Figura 2.

Figura 2 – Representação esquemática da distribuição vertical da água no solo, mostrando as diferentes zonas de umidade



Fonte: MANOEL FILHO (2008).

A zona não saturada ou de aeração pode ser dividida em três partes, sendo elas:

- a zona de água no solo ou zona de evapotranspiração que fica situada entre os extremos das raízes das plantas e a superfície do terreno. Pode variar entre centímetros (ausência de cobertura vegetal) e vários metros (vegetação abundante) e representa o domínio onde as plantas utilizam a água capilar para suas funções de transpiração e nutrição;
- a zona intermediária que compreende o limite de ascensão capilar da água e o limite de alcance das raízes das plantas, a umidade existente nessa região é proveniente das águas de retenção por forças não capilares e por água capilar isolada (fora do alcance das raízes);
- zona capilar que se estende da

superfície freática até o limite de ascensão capilar da água. A espessura dessa zona é variável e depende da distribuição de tamanho dos poros e homogeneidade do terreno, adota-se como conceito de franja capilar o limite abaixo do qual o solo é considerado praticamente saturado (cerca de 75%) (MANOEL FILHO, 2008).


Na zona de saturação, a água subterrânea preenche todos os interstícios; portanto, a porosidade fornece uma medida direta da água contida por unidade de volume. Uma parte da água pode ser removida dos estratos subterrâneos por drenagem ou bombeamento de um poço; no entanto, as forças de tensão superficial e molecular mantêm o restante da água no lugar (TODD; MAYS, 2005). A Figura 2 mostra a distribuição vertical da água no solo nas diferentes zonas de umidade.

O lençol freático delimita as zonas de saturação e aeração. É definido como a superfície na qual a pressão de fluido nos poros é exatamente a atmosférica e a carga hidráulica em qualquer ponto do nível freático é igual a sua elevação naquele ponto (FREEZE; CHERRY, 2017; CPRM, 2018).

Geralmente, o lençol freático acompanha a superfície do terreno. A sua configuração é uma função da geometria da superfície, da taxa e da localização da recarga e descarga da água subterrânea, das propriedades e extensão do aquífero e das unidades confinantes adjacentes (SNYDER, 2008). As alterações nas taxas de recarga ou descarga das águas subterrâneas causam mudanças no armazenamento e são representadas pelas flutuações do lençol freático. Dessa forma, a altura do lençol freático aumenta devido ao maior armazenamento subterrâneo, quando a taxa de recarga excede a taxa de descarga, e diminui quando essas condições são inversas (VEEGER; JOHNSTON, 1996).

A direção do fluxo de água subterrânea depende da carga hidráulica, fluindo da maior para a menor carga hidráulica. Portanto, conforme Snyder (2008), o mapeamento da configuração do lençol freático pode ser usado para inferir a direção horizontal do fluxo de água subterrânea. Os mapas de elevação também podem ser úteis para identificar os sistemas de escoamento, ajudando, assim, a identificar e diferenciar as áreas de recarga e descarga, bem como a presença de águas subterrâneas locais, intermediárias e regional (Figura 3).

Figura 3 – Representação esquemática de um sistema de fluxo de água subterrânea



Fonte: KLØVE et al. (2014).

Os aquíferos são camadas ou formações geológicas suficientemente permeáveis para permitir o movimento natural da água em seu interior. Consistem, então, em reservatórios capazes de armazenar e de transmitir a água subterrânea. São classificados de acordo com o tipo de rocha armazenadora (sedimentar, fraturado e cárstico) e segundo suas características hidráulicas, sendo livre ou confinado (IRITANI; EZAKI, 2012).

No Brasil, em geral, as reservas renováveis de água subterrânea correspondem a 24% do escoamento dos rios e a 49% da vazão de estiagem (considerada como a vazão de estiagem com 95 % de permanência). Os principais sistemas aquíferos sedimentares ocupam aproximadamente 32% do território e estão associados as grandes bacias sedimentares como a Bacia do Paraná (contendo os sistemas aquíferos Bauru-Caiuá, Guarani, Tubarão, Ponta Grossa e Furnas); Bacia do Parnaíba (sistemas aquíferos Itaperucu, Corda, Motuca, Poti-Piauí, Cabeças e Serra Grande); e Bacia do Amazonas (com os sistemas aquíferos Boa Vista, Solimões e Alter do Chão) (HIRATA et al., 2010).

2.2.1 Variáveis ambientais que influenciam nos níveis de água subterrânea

De acordo com Snyder (2008), a posição do lençol freático é dinâmica e muda constantemente em resposta as tensões induzidas pelo homem e pela natureza. As flutuações do nível freático podem ocorrer em diferentes escalas de tempo, como ao longo de horas, em resposta a eventos de precipitação de alta intensidade, ou ao longo de décadas, fruto das mudanças climáticas ou do uso da terra. Além disso, as interações com as águas superficiais (como rios, pântanos e lagos) também influenciam na posição do lençol freático.

A infiltração é o processo mais importante de recarga de água no subsolo, o volume e a velocidade de água infiltrada depende de vários fatores, tais como (KARMANN, 2003; HEALY, 2010):

a) Tipo e condição dos materiais terrestres: as características do solo, resultado das interações de diversos fatores ambientais, é capaz de influenciar os processos naturais que ocorrem no local. A capacidade do solo de armazenar água está relacionada tanto com a porosidade, representada pelo volume de poros vazios em relação ao volume total, quanto com a permeabilidade, que indica a capacidade de permitir o fluxo de água pelos poros. A permeabilidade se relaciona com o tamanho e o volume dos poros interconectados, a forma, a distribuição e a variação do tamanho dos grãos que compõem o solo ou a rocha. Dessa forma, materiais porosos e permeáveis, como solos e sedimentos arenosos, bem como as rochas porosas ou muito fraturadas, favorecem a infiltração. Por outro lado, materiais argilosos e rochas cristalinas pouco fraturadas, são desfavoráveis ao processo (IRITANI; EZAKI, 2012; GOETTEN, 2015).

Espessas coberturas de solo exercem o controle da infiltração, retendo temporariamente parte da água e liberando-a lentamente para a rocha adjacente. A quantidade de água transmitida pelo solo depende de sua capacidade de campo, que corresponde ao volume de água absorvido pelo solo antes de atingir a saturação, e que não sofre movimentos para níveis inferiores. Este parâmetro é importante, pois representa o volume de água que se encontra no solo, mas que não contribui com a recarga de água subterrânea, sendo aproveitada somente pela vegetação (KARMANN, 2003).

b) Topografia: o relevo tem influência no fluxo de água dentro de uma bacia hidrográfica. Todo o volume de água captado não infiltrado é automaticamente

escoado por meio da rede de drenagem das áreas de maior elevação (maior energia potencial) para as áreas de menor elevação (menor energia potencial), obedecendo a uma hierarquia fluvial, até se concentrar em um único ponto, formando um rio principal (PORTO; PORTO, 2008). Os canais de fluxo representam mínimos topográficos que cortam a bacia hidrográfica.

Portanto, dados topográficos são importantes, principalmente, para delinear os limites das bacias hidrográficas correspondentes a um ponto de descarga e para entender os processos de escoamento superficial. Os dados de elevação são úteis para diversos fins como no desenvolvimento de parâmetros para modelagem hidrológica, no mapeamento de umidade do solo, na avaliação das taxas de erosão e na determinação da superfície potenciométrica de um aquífero (DIXON; UDDAMERI, 2016).

c) Precipitação: a distribuição da precipitação ao longo do ano é decisiva no volume de recarga da água subterrânea, em qualquer tipo de terreno. Chuvas que são regularmente distribuídas ao longo do tempo promovem uma maior infiltração. Ao contrário, em chuvas torrenciais, a taxa de infiltração é inferior ao volume de água precipitado em um curto período (KARMANN, 2003).

A profundidade do nível da água pode sofrer oscilações ao longo do ano, variando de acordo com o clima e as mudanças do tempo. Em áreas naturais, períodos chuvosos tendem a gerar uma maior infiltração e, por consequência, a elevação dos níveis freáticos; já nos de estiagem, onde o processo de evapotranspiração é maior e a infiltração é baixa, o nível da água tende a ser mais profundo (IRITANI; EZAKI, 2012).

d) Uso e ocupação da terra: nas áreas urbanas, as construções e pavimentações impedem a infiltração, o que gera problemas devido ao aumento do escoamento superficial e redução da recarga da água subterrânea. Em áreas rurais, a infiltração sofre redução, em geral, pela exposição das vertentes por plantações sem terraceamento e pela compactação do solo pelo pisoteamento de animais (KARMANN, 2003).

e) Cobertura vegetal: áreas vegetadas favorecem a infiltração por meio de suas raízes que abrem caminho para as águas descendentes. A vegetação também exerce influência na quantidade de água que chega ao solo por meio da interceptação, onde uma parcela é retida sobre folhas e caules, o que diminui o impacto das gotas da chuva sobre o solo e reduz a sua ação erosiva (KARMANN, 2003).

Além de reter boa quantidade de água, a presença da vegetação pode diminuir a temperatura ambiente com sombreamento gerado, o que reduz substancialmente a evaporação, dando tempo para que a infiltração ocorra (CPRM, 2018). De acordo com Rebouças et al. (2002), as maiores taxas de recargas são encontradas em regiões planas, arborizadas e nos aquíferos livres.

Ressalta-se, ainda, o processo de evapotranspiração como uma variável importante do ciclo hidrológico, pois estabelece relação entre a energia, a disponibilidade hídrica e o clima (GHARBIA et al., 2018). Para Von Asmuth et al. (2002), em um sistema linear, uma série de alturas de lençol freático é a transformação de uma série de precipitação na qual se desconta a evapotranspiração potencial.

Segundo Martinet et al. (2009), a evapotranspiração, que combina a transpiração das plantas com a evaporação da superfície do solo, é um fluxo eco-hidrológico, que pode ser usado para avaliar os impactos da vegetação sobre os recursos hídricos subterrâneos. Variações sazonais nas flutuações freáticas induzidas pela evapotranspiração podem servir como uma ferramenta para inferir os padrões de consumo da vegetação. Diversos estudos vêm sendo realizados a fim de compreender essas relações, tais como o Healy e Cook (2002), Butler et al. (2007) e Millar et al. (2018).

2.3 Modelagem dos recursos hídricos em SIG

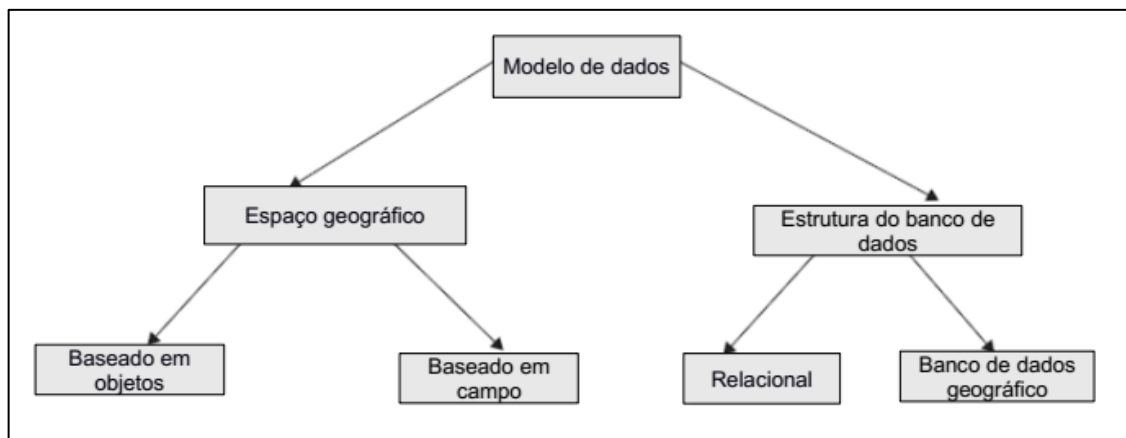
A concepção da modelagem se origina da representação de um sistema físico por meio de equações. Isto é, a representação do comportamento de uma estrutura que num dado intervalo de tempo se relaciona com uma entrada ou um estímulo e resulta em uma resposta ou uma saída perante a tal perturbação (TUCCI, 2005; MARINHO FILHO et al., 2013). Um modelo é fruto do conhecimento do modelador sobre um fenômeno observado e, por essa razão, um determinado fenômeno pode ser modelado de diferentes formas (CHRISTOFOLLETTI, 1999).

Os modelos são abstrações da realidade e se justificam pela necessidade de se conhecer o comportamento de um sistema. São instrumentos úteis para o gerenciamento dos recursos hídricos, pois permitem a simulação de cenários e a projeção de condições futuras (TUCCI, 2005).

Para Dixon e Uddameri (2016), as ferramentas de SIG são capazes de produzir representações, modelos ou aproximações da realidade ao relatar as informações

sobre o mundo real como uma série de entradas discretas que compõem bancos de dados. Para que um resultado seja preciso, os modelos de dados devem conter informações detalhadas sobre o que se pretende representar e, também, apresentar uma simplicidade suficiente para funcionar de maneira eficaz nos recursos de processamento, armazenamento e recuperação dos computadores. Em um SIG, o espaço geográfico pode ser representado por meio de um modelo de dados baseado em objetos e/ou de um modelo baseado em campo (Figura 4).

Figura 4 - Classificação de dados geográficos com base no modelo de dados




Fonte: DIXON; UDDAMERI (2016).

Conforme Dixon e Uddameri (2016), um modelo de dados baseado em objetos se preocupa com os objetos espaciais discretos e identificáveis encontrados em um espaço geográfico particular. Esses objetos devem ter limites definidos e extensão espacial, características que podem ser descritas como atributos. Existem dois tipos de objetos: (i) objetos espaciais exatos e (ii) objetos espaciais inexatos. Um objeto espacial exato é um recurso discreto com limites definidos, como poços de água potável e poços de irrigação. Um objeto espacial inexato (ou difuso) tem uma extensão espacial identificável, mas os limites são transitórios e não precisos, como no caso dos solos. Os dados para esses modelos são coletados usando vários métodos de campo (incluindo métodos de levantamento topográfico, GPS e investigação do local) e métodos de laboratório, como fotointerpretação e processamento de imagens. Os objetos espaciais podem ser representados em um modelo de dados vetoriais com elementos gráficos como pontos (dados locais), linhas (hidrologia) e polígonos (solos e geologia).

Um modelo de campo está preocupado principalmente com o espaço geográfico, assumindo que esse é ocupado por fenômenos que variam continuamente sobre o espaço sem limites óbvios ou específicos (Figura 5). Alguns exemplos de tais dados são Redes Irregulares Trianguladas (TINs), superfícies interpoladas e dados topográficos, como contornos e Modelo Digital de Elevação. Esses modelos de dados baseados em campo podem ser obtidos direta ou indiretamente. Métodos diretos para aquisição de dados de campo incluem fotografia aérea e imagens de satélite. Métodos indiretos incluem a aplicação de funções matemáticas como interpolação, reclassificação e reamostragem dos dados medidos em campo (DIXON; UDDAMERI, 2016).

A Figura 5 ilustra o funcionamento dos modelos em SIG pela representação de um mundo real ligado por localização comum. A realidade é dividida em camadas que são separadas por temas e por tipos de dados que incluem elevações, hidrologia, solos, geologia, dados do local, imagens, entre outros.

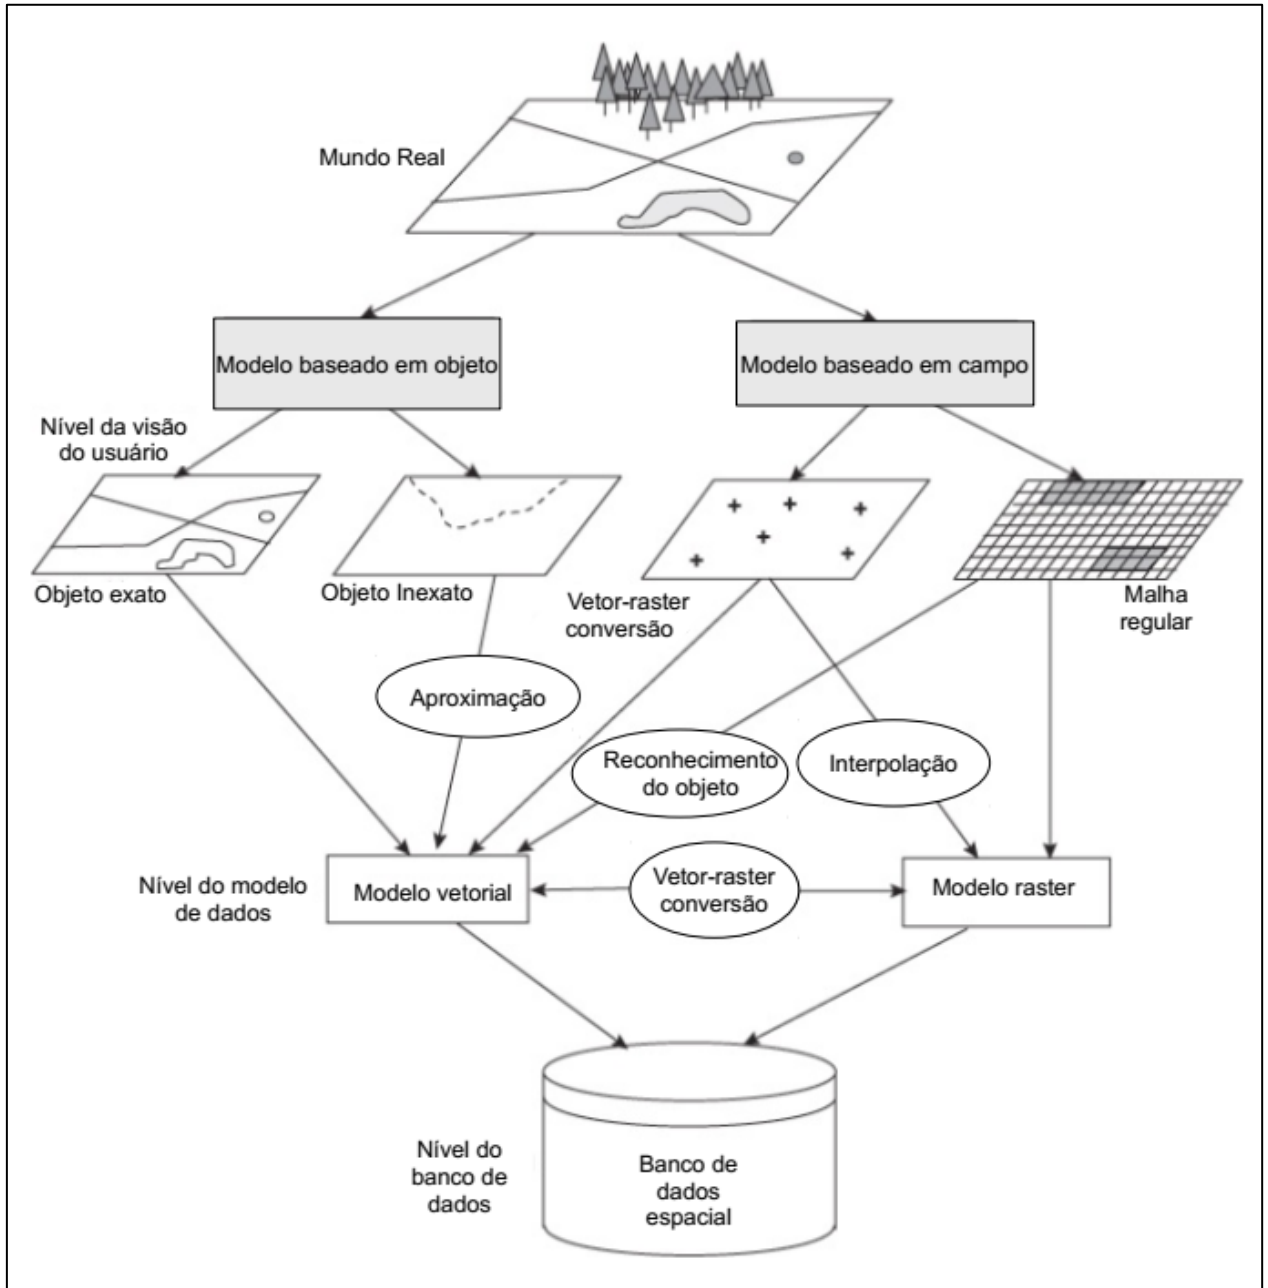
Figura 5 - Camadas de informações gerenciadas pelo SIG



Fonte: DIXON; UDDAMERI (2016).

Lo e Yeung (2007) descrevem um diagrama conceitual para representar o mundo real em um banco de dados espacial, Figura 6.

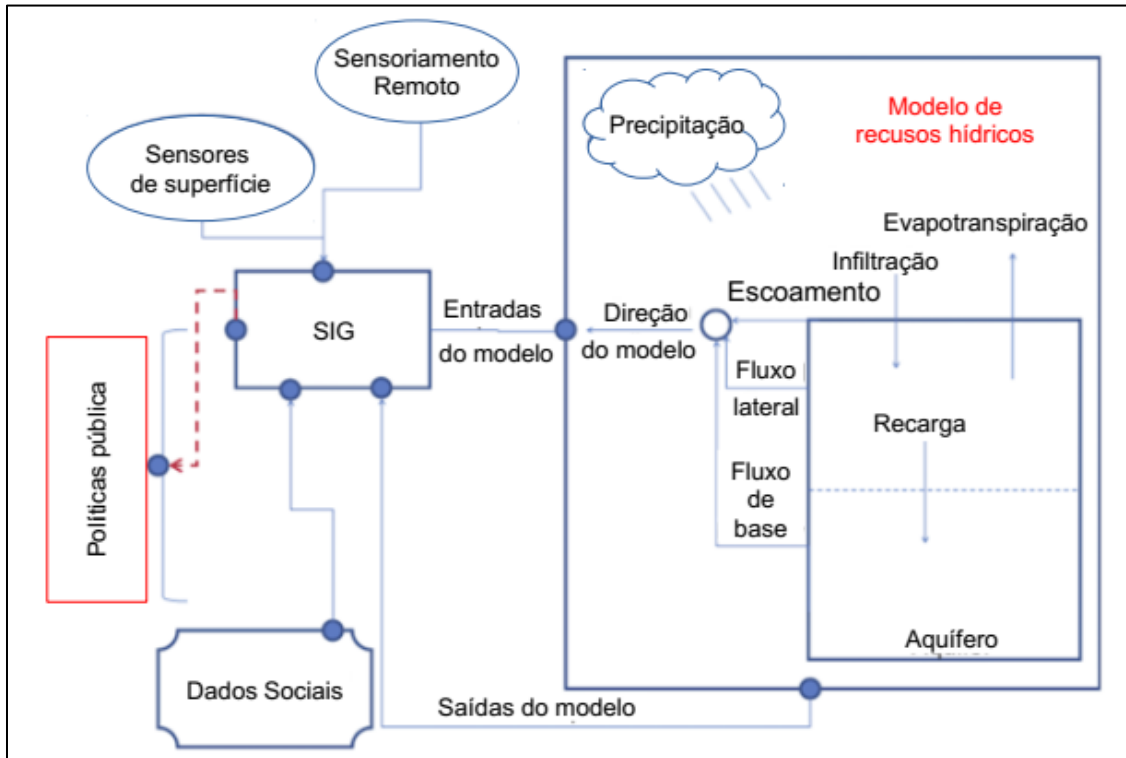
Figura 6 - Abordagens usadas para representar o mundo real



Fonte: LO; YEUNG (2007).

A utilização de um SIG pode ser útil na transferência de dados obtidos a partir de sensoriamento remoto, bem como de outras fontes, para desenvolver insumos aos modelos de recursos hídricos, conforme a Figura 7.

Figura 7 - Fluxo de trabalho de informações representando o acoplamento de modelos de sensoriamento remoto, SIG e bacias hidrográficas



Fonte: DIXON; UDDAMERI (2016), traduzido pela autora.

As informações geradas a partir do modelo podem ser combinadas com outros dados a fim de descrever como as dimensões natural e humana interagem. O SIG é especialmente útil no mapeamento e modelagem de recursos hídricos porque executa as seguintes funções: 1) Recebe e reúne dados dispersos de várias origens; 2) Melhora o gerenciamento e a análise de dados; 3) Aperfeiçoa a compreensão das interações entre recursos hídricos e a superfície; 4) Possibilita visualizações em 3D e ao longo do tempo, cálculos e teste de hipóteses, minimizando o erro humano e a subjetividade; 5) Suporta modelagem estatística e numérica; 6) Permite aplicar efetivamente os dados detectados remotamente (DIXON; UDDAMERI, 2016).

2.4 Modelagem multivariada de dados

A Análise de Dados Multivariada trata de dados provenientes de diversas medidas obtidas sobre uma mesma amostra, considerando não apenas as características particulares de cada uma das medidas com relação a amostra, mas, também, as possíveis relações existentes entre as múltiplas variáveis utilizadas na pesquisa (ANDRIOTTI, 1997).

Os métodos da estatística multivariada são utilizados com o objetivo de simplificar a interpretação do fenômeno em estudo pela construção de índices ou variáveis alternativas capazes de sintetizar a informação original. Suas ferramentas possibilitam investigar as relações de dependência entre as variáveis, comparar populações e validar testes de hipóteses. Entre as técnicas de análise multivariada, estão a análise de correlação canônica, regressão logística, análise de agrupamentos (ou cluster), análise multivariada da variância (MANOVA), análise fatorial e análise de componentes principais (PCA) (MINGOTI, 2005; FRANÇA, 2009).

Os métodos estatísticos multivariados vêm sendo aplicado nos estudos das águas subterrâneas e têm auxiliado na identificação dos mecanismos que afetam as características desses recursos hídricos (CERAR; MALI, 2016; KIM et al., 2005). De acordo com Prasanna et al. (2010), as ferramentas da estatística multivariada podem ser úteis, por exemplo, no entendimento dos fluxos de águas subterrâneas em sistemas de aquíferos complexos.

2.4.1. Análise de Componentes Principais (PCA)

A PCA é um método da estatística multivariada que estuda a relação de interdependência de um conjunto de variáveis de um sistema. Para Kendall (1980), entre as contribuições da análise de componentes principais para o estudo, estão:

1. Simplificação da estrutura de dados por meio da transformação de um conjunto de dados.
2. Agrupamento das observações e das variáveis segundo suas similaridades.
3. Avaliar a importância de cada caractere e proporcionar a eliminação daqueles que contribuem pouco, em termos de variação, no grupo de indivíduos avaliados;

A PCA é um método exploratório e tem como objetivo identificar padrões nos dados e expressá-los de uma maneira na qual suas semelhanças e diferenças sejam destacadas. Uma vez que os padrões são reconhecidos, é possível compactar o número de variáveis, reduzindo, então, o número de dimensões do estudo com a menor perda possível de informações (SAVI, 2017).


A PCA consiste em uma transformação linear de todas as variáveis originais em novas variáveis, onde a primeira nova variável computada é responsável pela maior parte da variação possível existente no conjunto de dados, a segunda pela maior variação remanescente, e assim por diante até que toda variação do conjunto seja

explicada (BERNARDI et al., 2009). A PCA foi avaliada por Wang e Du (2000) como uma técnica robusta, capaz de trabalhar com dados não normais com alto desempenho.

Dessa forma, a transformação realizada no processo de PCA resulta em um conjunto de variáveis de mesma dimensão denominadas de componentes principais (PC). Os PC apresentam propriedades relevantes: cada PC é uma combinação linear de todas as variáveis originais, são independentes entre si e estimados com a finalidade de reter o máximo de informação, em termos da variação total presente nos dados (CRUZ et al., 2012).

Conforme Johnson e Wichern (1992), geometricamente, as PC representam um novo sistema de coordenadas obtido pela rotação dos sistemas originais. Os eixos formados indicam as direções da máxima variabilidade. A Figura 8, apresentada por Caten (2008), considera uma amostra com duas variáveis de n observações. Obtêm-se, pela rotação dos eixos, um novo sistema de coordenadas, em que Y_1 representa o eixo principal e Y_2 o eixo secundário, sendo α_1 e α_2 os ângulos formados entre os eixos originais X_1 e X_2 e os eixos Y_1 e Y_2 do novo sistema de coordenadas. A direção dos eixos é determinada pelos autovetores, aplicando-se aos ângulos os cossenos diretores ($e_{11} = \cos(\alpha_1)$ e $e_{21} = \cos(\alpha_2)$). Os autovalores λ_1 e λ_2 representam a variabilidade contida em cada um dos novos eixos.

Figura 8 - Sistema de coordenadas X_1 e X_2 , novo sistema Y_1 e Y_2 , ângulos de rotação dos novos eixos e autovalores



Fonte: CATEN (2008).

Muitos pesquisadores têm utilizado a análise de componentes principais para resolver problemas como da multicolinearidade das variáveis, pois permite transformar um conjunto de variáveis originais intercorrelacionadas em um novo conjunto de variáveis não correlacionadas; para realizar a modelagem da interação entre fatores em experimentos sem repetição; em estudos de divergência e agrupamento; entre outras possibilidades (HONGYOU et al., 2015).

2.5 Modelagem espacial de dados geográficos

De acordo com Soares (2006), a geoestatística objetiva a caracterização da dispersão espacial e espaço-temporal das grandezas que definem os recursos naturais ou de outros fenômenos espaciais em que os atributos manifestam certa disposição no espaço e/ou no tempo. Sua fundamentação consiste em conjuntos de instrumentos estatísticos que quantificam a continuidade espacial da grandeza em estudo, em modelos de interpolação espacial tendo como base a variabilidade estrutural e em modelos de simulação estocástica que quantificam a incerteza ligada ao fenômeno espacial. Segundo o autor, os fenômenos espaciais estruturados, possuem duas características comuns que são a razão para a aplicação dos modelos probabilistas: em primeiro lugar, são entidades que se distribuem no espaço de forma não aleatória, ou seja, com certa estrutura; em segundo lugar, a informação disponível sobre o fenômeno espacial é, em sua maioria, discreta e normalmente escassa, fazendo com que o seu conhecimento global seja sempre associado à ideia de incerteza.

2.5.1 Variabilidade espacial dos dados

De acordo com Matheron (1971), uma variável regionalizada (VR) é uma função $f(x)$ do ponto x , mas também se caracteriza como uma função irregular com dois aspectos complementares: o primeiro relacionado à aleatoriedade no qual a variabilidade e irregularidade não permitem prever as variações de um ponto a outro; e o segundo a um aspecto estruturado que exhibe as relações existentes entre os pontos no espaço motivadas pela sua gênese (YAMAMOTO; LANDIM, 2013).

Assim, a VR apresenta um comportamento espacial que mostra características intermediárias entre as variáveis verdadeiramente aleatórias e as totalmente

determinísticas. No estudo do comportamento das VR o semivariograma (que descreve a estrutura da variabilidade espacial) e a krigagem (que estima os valores não amostrados, com variância mínima) são as ferramentas fundamentais dos métodos geoestatísticos (LANDIM, 2006).

A teoria das VR pressupõe que cada informação $Z(x_i)$ é modelada como uma variável aleatória expressa pela soma de três componentes, sendo um componente estrutural associado a um valor médio constante ou a uma tendência constante, um componente aleatório, espacialmente correlacionado, e um erro aleatório. Assim, se x representa uma posição de uma, duas ou três dimensões, então o valor da variável Z , em x , é dado pela Equação 1 (GUEDES, 2013).

$$Z(x_i) = M(x) + \varepsilon'_x + \varepsilon_i \quad (1)$$

Onde, $M(x)$ corresponde a uma função determinística que descreve a componente estrutural Z em x ; ε'_x é um termo estocástico, que depende de $M(x)$, variando localmente; e ε_i é um ruído aleatório não correlacionado.

De acordo com Landim (2006), o semivariograma é uma ferramenta que mede grau de dependência espacial entre amostras ao longo de um suporte específico. Para a sua elaboração, utiliza-se as diferenças ao quadrado dos valores obtidos, assumindo-se uma estacionaridade nos incrementos. O semivariograma é, assim, uma medida de variabilidade condicionada pela distância. A variação entre dois pontos separados por uma distância h é definida pela função expressa na Equação 2 (MELLO et al., 2005).

$$2\gamma(x, h) = E[Z(x_i) - Z(x_i + h)]^2 \quad (2)$$

Conforme Mello et al. (2005), por meio da Equação 2 tem-se que a função variográfica depende tanto da localização (x) quanto da distância (h). Assim, para que o semivariograma seja apenas função de h , é preciso empregar a hipótese intrínseca. Ressaltando que havendo estacionaridade de segunda ordem, existe uma relação direta entre a correlação e a semivariância (Equação 3).

$$y(h) = C(0) - C(h) \quad (3)$$

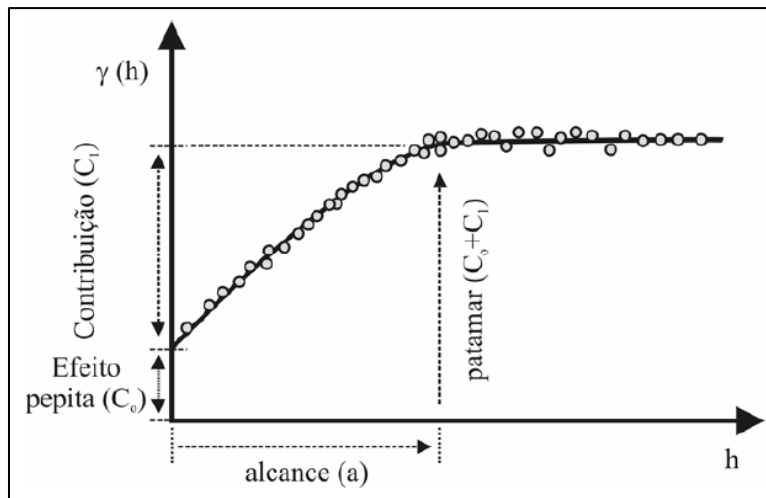
Onde, $C(0)$ corresponde à variância total dos dados e $C(h)$ corresponde à correlação entre dois pontos separados por uma distância h . Segundo Mello et al. (2005), o estimador da semivariância $\hat{y}(h)$ corresponde à metade da esperança da variância entre os pares de pontos separados por uma distância h . Obedecendo à hipótese intrínseca, a semivariância pode ser estimada por uma única realização do processo estocástico (Equação 4).

$$\hat{y}(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i + h)]^2 \quad (4)$$

Onde, $\hat{y}(h)$ é a semivariância estimada entre pares de pontos; $N(h)$ é o número de pares medidos para uma dada distância h ; $Z(x_i)$ e $Z(x_i + h)$ são as observações das VR nas posições x_i e $x_i + h$; e h é a distância entre as duas observações.

Segundo Oliveira et al. (2009), para propriedades espacialmente dependentes, espera-se que a diferença entre valores $Z(x_i) - Z(x_i + h)$ seja crescente com a distância até se estabilizar em um valor denominado de patamar (C_i , *sill*) que é aproximadamente igual à variância dos dados. Essa distância é conhecida como alcance (α , *range*) e representa o raio de um círculo, no qual a similaridade dos valores é tanta que os valores são correlacionados. O valor da semivariância na interseção do eixo Y representa a variabilidade da propriedade em estudo em espaçamentos menores do que o amostrado, recebendo o nome de efeito pepita (C_0). Deste modo, quanto maior o efeito pepita, mais fraca é a dependência espacial de um atributo, Figura 9.

Figura 9 - Representação gráfica de um semivariograma



Fonte: VIEIRA (2000).

Segundo Scolforo (2014), a função semivariograma possibilita gerar o gráfico da semivariância, denominado de semivariograma experimental, que permite a interpretação da continuidade espacial da VR, sendo a qualidade deste ajuste

A verificação do ajuste do semivariograma pode ser feita por meio da validação cruzada (MORAES, 2015). Nesse procedimento, realizado para todos os pontos amostrados, ignora-se o valor no ponto de mensuração e obtém-se a estimativa do mesmo com base nos valores dos pontos vizinhos (ANDRIOTTI, 2003).

A validação cruzada permite avaliar o modelo por meio cálculo do erro médio (ME) e da raiz do erro médio quadrático padronizado (RMSS). O RMSS fornece informação sobre a acurácia da predição e deve se aproximar de 1 (JOHNSTON et al., 2001). Segundo Teixeira et al. (2011), para indicar uma validação robusta dos resultados, o valor do EM deve ser próximo de zero.

2.5.2 Interpolação geoestatística - Krigagem

Segundo Landim (2003), a krigagem é um processo de estimativa de valores de variáveis distribuídas no espaço, e/ou no tempo, a partir de valores adjacentes enquanto considerados interdependentes pelo semivariograma. O método pode ser utilizado, por exemplo, para previsão do valor pontual de uma variável regionalizada em um determinado local dentro do campo geométrico e para a estimativa de deriva, de forma similar à análise de superfícies de tendências.

A krigagem, então, busca no semivariograma as informações necessárias para atribuir pesos ótimos a serem associados às amostras que irão estimar um ponto ou um bloco, sendo possível obter, ao final do processo, não apenas os valores estimados, mas também os erros associados ao procedimento. Esse interpolador viabiliza a melhor estimativa de locais não amostrados, pela minimização da variância do erro. Entretanto, não há garantias que o mapa gerado pelo método tenha o mesmo semivariograma e a mesma variância dos dados originais, pois apresenta valores suavizados (LANDIM, 2003).

Conforme Mello et al. (2003), a krigagem pode ser expressa pelas Equações 6 e 7.

$$[A]^{-1} \cdot [b] = [\lambda] \quad (6)$$

Onde, $[A]^{-1}$ representa a matriz inversa de semivariância entre as localidades da vizinhança de um ponto, determinada pelo modelo de semivariograma com base nas distâncias euclidianas entre as localidades; $[b]$ é a matriz de semivariância entre as localidades vizinhas (com a variável estimada) e o ponto para o qual a variável será interpolada, também determinado pelo modelo de semivariograma, com base nas distâncias entre as localidades vizinhas e o ponto a ser interpolado; $[\lambda]$ é a matriz de pesos de krigagem.

$$X_p = \sum_{i=1}^n \lambda_i X_i \quad (7)$$

Onde, X_p corresponde à variável interpolada; λ_i ao peso da i -ésima localidade vizinha; X_i ao valor da variável para a i -ésima localidade; n ao número de localidades vizinhas empregadas para interpolação do ponto.

2.5.2.1 Krigagem Ordinária

Na Krigagem ordinária (KO), de acordo com Goovaerts (1999), pressupõe-se que as médias das variáveis sejam constantes, porém desconhecidas. As flutuações locais

da média são consideradas, limitando-se o domínio de sua estacionaridade para a vizinhança local. O estimador linear é definido conforme a Equação 8.

$$\hat{Z}_{x_0} = \sum_{i=1}^n \lambda_i Z_{x_i} \quad (8)$$

Onde, \hat{Z}_{x_0} é o estimador na posição x_0 (média ponderada dos dados); n é o número de pontos amostrais vizinhos utilizados para a predição do valor não amostrado; λ_i é o i -ésimo peso atribuído a cada i -ésima observação da variável de interesse na posição x , Z_{x_i} , definido pelo semivariograma.

Soares (2006) ressalta que existem fenômenos nos quais os valores do atributo que se deseja estimar não apresenta um comportamento considerado homogêneo dentro da área amostrada como, por exemplo, os valores que crescem de um modo sistemático em uma dada direção ou os valores que são mais elevados e se concentram localmente em um ponto ou área, decrescendo de um modo radial em todas as direções. Nessas situações, em que existe clara deriva dos valores das médias das variáveis aleatórias, não é possível considerar a hipótese de estacionaridade da média, ou seja, de considerá-la constante para todo o domínio. Para isso, existem métodos que consideram a forma da deriva ou a variação das médias locais, sendo eles: krigagem simples, krigagem com modelo de deriva e krigagem com deriva externa.

2.5.3 Regressão-krigagem

A regressão-krigagem (RK) é um método de interpolação espacial que combina a regressão de uma variável dependente de variáveis auxiliares (como parâmetros de superfície, imagens de sensoriamento remoto e mapas temáticos) com a krigagem ordinária dos resíduos (HENGL et al. 2007). A RK é um modelo geoestatístico híbrido que possibilita prever uma variável pela associação da modelagem de componentes determinísticos e estocásticos (Equação 1), elaboradas separadamente (HENGL, 2009; SCOLFARO, 2014; CARVALHO, 2016).

De acordo com Omuto e Vargas (2015), a componente determinística representa as tendências em larga escala e são modeladas por meio da análise de regressão,

que fornece uma visão geral do comportamento da variável principal. Enquanto a componente estocástica representa a autocorrelação em curta escala, sendo modelada com a análise da krigagem.

Para que o mapa final apresente um melhor detalhamento, é preciso que haja uma correção daquele elaborado apenas com base no modelo de regressão. Desta forma, a RK é aplicada aos resíduos gerados pelo modelo com o objetivo de corrigir as tendências, introduzindo um aspecto estocástico ao mapeamento. A aplicação de técnicas geoestatísticas híbridas tem se popularizado nos últimos anos ao permitir a utilização de informações secundárias disponíveis e ao alcançar previsões locais mais precisas, considerando, desta forma, as correlações ambientais (MELLO, 2013).

A análise de regressão é utilizada quando se pretende estabelecer a relação entre duas ou mais variáveis, fornecendo as funções que relacionam as variáveis. A relação entre a variável dependente e a variável independente é determinada por um modelo de regressão simples: $Y = f(X)$, o que permite a definição dos coeficientes “a” e “b” da equação de uma reta, caso a relação seja linear. Quando duas ou mais variáveis independentes são consideradas para descrever o sistema, define-se os coeficientes “a” e coeficientes para todos os termos X_1, X_2, \dots, X_n (MILONE; ANGELINI, 1995; CARVALHO, 2015).

Conforme Sassi et al. (2012), a regressão linear múltipla é um recurso multivariado, que permite reduzir muitas variáveis para poucas dimensões e possibilita a detecção dos principais padrões de similaridade, associação e correlação entre as variáveis. A inclusão de novas variáveis na equação de ajuste pode ser feita para aumentar o grau de correlação entre os dados teóricos e reais. O resultado do modelo é um único valor, que representa uma combinação do conjunto inteiro de variáveis que melhor atinge o objetivo da análise multivariada específica.

O modelo de regressão linear múltipla pode ser expresso conforme a Equação 9:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + e \quad (9)$$

Onde: X_n é a n ésima variável independente; β_n é o coeficiente associado à n ésima variável e e corresponde ao erro, isto é, a variabilidade de Y não explicada pela relação linear.

De acordo com Landim (2003), a variância total da variável dependente (Y) é em parte explicada pelas diversas variáveis independentes e o restante pela variabilidade devida ao erro. A proporção da variância dos Y observados é explicada por uma equação de regressão ajustada, representada pelo coeficiente de determinação R^2 cujos valores se dispõem entre 0 e 1.

Segundo Hengl et al. (2003), a krigagem universal, krigagem com deriva externa e regressão-krigagem pertencem ao grupo dos modelos “híbridos” aplicados em casos de não estacionariedade dos dados. Na krigagem universal, a tendência é modelada em função apenas das coordenadas, baseando-se nos valores de localização para elaborar a regressão. Na krigagem com deriva externa a tendência é definida por meio de variáveis auxiliares. E, na regressão-krigagem, a tendência e resíduos são modelados separadamente e somados posteriormente.


Dessa forma, considerando que as componentes da variação espacial podem ser modeladas separadamente, tem-se por meio da igualdade descrita na Equação 10, o modelo geral de regressão-krigagem (HENGL, 2009).

$$\hat{Z}(x_0) = m(x_0) + \varepsilon(x_0) = \sum_{k=0}^p \beta_k \cdot q_k(x_0) + \sum_{i=1}^n \lambda_i \cdot e(x_i) \quad (10)$$

Onde $\hat{Z}(x_0)$ é o valor predito da variável de interesse, $m(x_0)$ é a tendência modelada e $\varepsilon(x_0)$ os resíduos interpolados. β_k são os coeficientes do modelo de tendência, λ_i são pesos de krigagem determinados pela estrutura de dependência espacial residual e $e(x_i)$ é o resíduo no local x_i .

A Figura 10 representa o ajuste do modelo por regressão-krigagem, onde se observa a estimativa final da variável $\hat{Z}(s)$ - em que s representa a posição no espaço, dada por coordenadas conhecidas – as amostras de campo, a tendência e os resíduos.

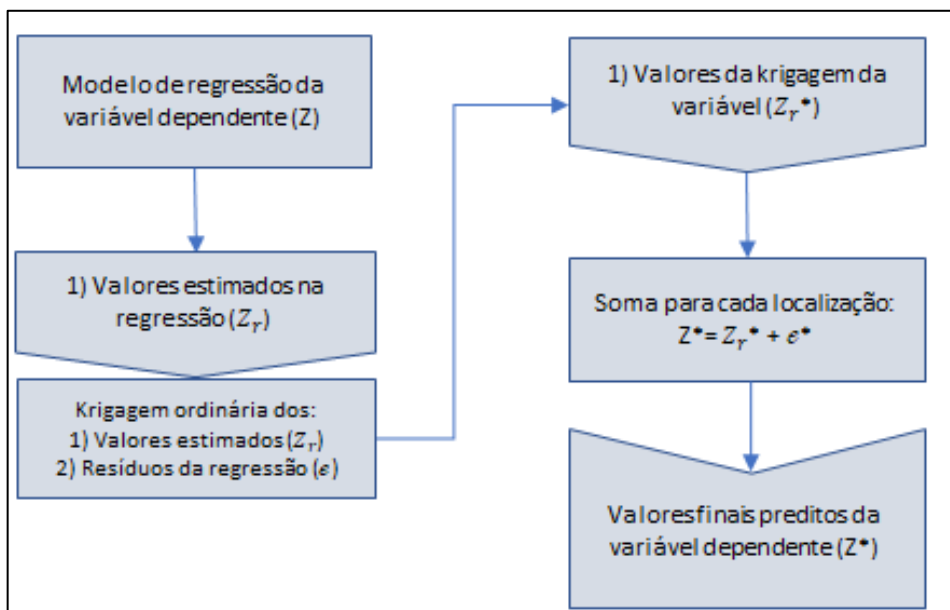
Figura 10 – Representação do ajuste espacial de uma variável ambiental por meio da regressão-krigagem



Fonte: HENGL (2009).

Na RK, uma vez que o modelo determinístico é alcançado, a próxima etapa consiste em avaliar a autocorrelação espacial dos resíduos. A partir disso, aplicar a krigagem ordinária aos resíduos e aos valores estimados de lençol freático, onde a soma dos mapas possibilita gerar um mapa final ajustado para os valores de água subterrânea nas bacias estudadas. As etapas do modelo de regressão-krigagem, esquematizadas por Odeh (1995), são apresentadas no fluxograma da Figura 11.

Figura 11 - Processo de modelagem por KR



Fonte: ODEH (1995).

A autocorrelação espacial é avaliada por meio do ajuste do semivariograma. Segundo Dixon e Uddameri (2016), a autocorrelação espacial descreve relações espaciais de dados geográficos, explorando a estrutura de covariância espacial em dados de atributos. Em vez de assumir que os valores nos locais sem amostragem são distribuídos uniformemente sobre um espaço geográfico, a análise de autocorrelação explora como os valores das variáveis em um local são afetados pelas variáveis (e seus valores) encontradas em locais adjacentes. Locais e posições na paisagem são comparados (cada ponto com todos os outros pontos) para determinar a similaridade ou dissimilaridade. A autocorrelação espacial pode ser melhor explicada pela Primeira Lei da Geografia de Tobler (Tobler, 1970). Esta lei afirma que todos os fatos geográficos (fenômenos espaciais) se relacionam, mas os fatos mais próximos possuem uma relação mais forte.

O principal objetivo das análises e modelagem de semivariograma é construir um modelo que melhor calcule a estrutura de autocorrelação espacial do processo estocástico. Um semivariograma é um gráfico de semivariância em função do vetor de distância h entre os pontos amostrados. Todos os pares de amostras possíveis são agrupados em classes de aproximadamente mesma distância, chamadas de *lags*. A escolha da distância entre os pontos é um processo de tentativa e erro em que o objetivo é obter o máximo de detalhes com uma pequena distância (*lag distance*) (ENGLUND; SPARKS, 1991; DIXON; UDDAMERI, 2016).

Crosbie et al. (2018) estimaram a recarga da água subterrânea por meio da RK e do método do balanço de massa de cloreto. O método combinado foi desenvolvido para aumentar as estimativas pontuais de recarga usando o balanço de massa de cloreto para fornecer estimativas robustas de recarga e a sua incerteza associada. O estudo foi realizado nas bacias de carvão orientais de New South Wales (Austrália) e mostrou que a recarga é maior em aquíferos produtivos, como as dunas costeiras (acima de 100 mm/ano), Arenito Hawkesbury (até 100 mm/ano) e Arenito Pilliga (até 10 mm/ano) e menor nas Unidades Permianas (~1% da precipitação).

De Laco et al. (2017) utilizaram a RK para a modelagem e a predição das concentrações do gás radônio (Rn) no solo do distrito de Lecce, região da Apúlia na Itália. Além disso, realizaram uma análise comparativa entre as técnicas de interpolação espacial RK e KO, baseados em covariáveis obtidas por SIG. A análise mostrou que o uso do método RK, comparado ao outro método proposto, melhora a confiabilidade das estimativas. Os resultados do estudo mostraram que quase todos

os sítios Rn com altos níveis de concentração no solo estão localizados em áreas residenciais, altamente urbanizadas e caracterizadas por um grande número de edifícios de escolas públicas, especialmente creches e escolas primárias.

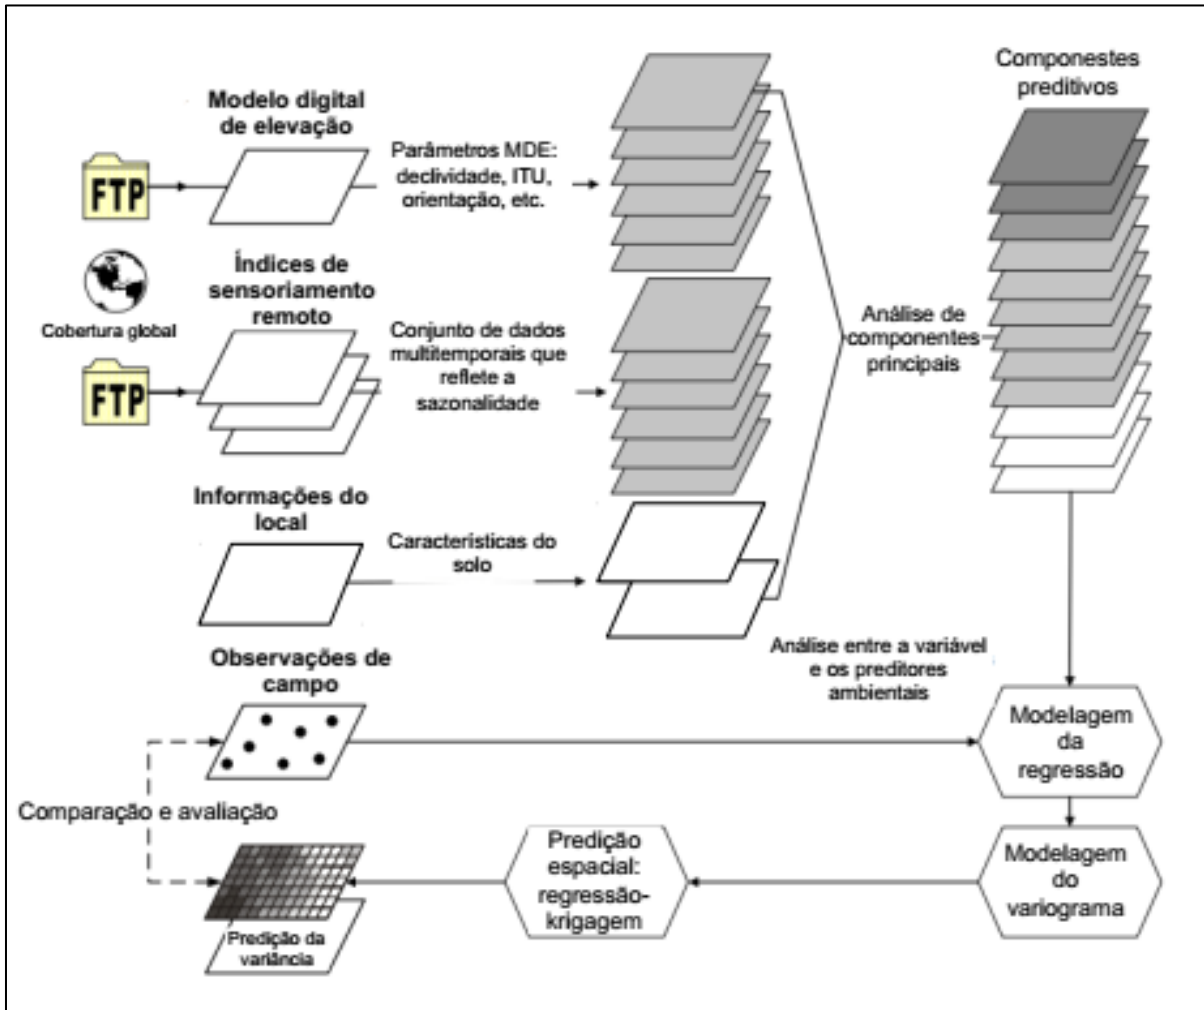
Menezes et al. (2016) utilizaram as técnicas de KO e de RK para prever as propriedades físico-químicas do solo na camada superficial. O estudo foi realizado em duas bacias hidrográficas com diferentes características de solo-paisagem e mostrou que em áreas com alta correlação linear entre covariáveis ambientais e atributo do solo, a RK apresentou melhor desempenho.

Ge et al. (2011) utilizaram a RK para caracterizar os solos com base em dados de sensoriamento remoto obtidos de um campo de algodão do Mississippi, EUA. O resultado mostrou que, incorporando apropriadamente a informação de correlação espacial dos resíduos de regressão, o modelo RK apresenta potenciais usos para futuras aplicações em agricultura de precisão, como o desenvolvimento de sensores de solo em tempo real e o mapeamento digital de solos.

3 MATERIAL E MÉTODOS

O processo para o mapeamento digital das águas subterrâneas pode ser visualizado na Figura 12.

Figura 12 - Estrutura para o mapeamento digital dos níveis freáticos com base na regressão-krigagem



Fonte: HENGL (2009), traduzido pela autora.

Em síntese, a modelagem teve início com o fornecimento de dados provenientes dos levantamentos do terreno, como MDE e declividade, dos índices de sensoriamento remoto e dos dados coletados em campo. Com base nesses dados, foram encontradas 21 variáveis explicativas.

A seleção daquelas que melhor explicaram a variabilidade geral dos dados foi feita por análise de componentes principais e reduziu o conjunto original de variáveis para 8. Em seguida, com base na significância das variáveis para o modelo determinístico,

uma nova seleção foi feita e resultou em 4 variáveis explicativas. O ajuste do modelo de regressão linear múltipla, se deu, então, com o Índice de Vegetação Ajustado ao Solo (SAVI), Índice de Vegetação Realçado (EVI2), níveis freáticos médios e porcentagem de areia e argila.

Uma vez que o modelo determinístico foi encontrado, os resíduos foram calculados e modelados por meio do semivariograma, obtendo-se, assim, as informações acerca da autocorrelação espacial. Por fim, os mapas com os níveis de água subterrânea e com os resíduos foram estimados pela krigagem ordinária e somados para a obtenção de um mapa predito final.

Ressalta-se que o levantamento de dados foi feito para o dia 10 de setembro de 2017 e que o modelo apresentou um ajuste robusto para essa data. A série histórica utilizada para a obtenção dos níveis freáticos máximo, médio e mínimo corresponde ao período entre março/2016 e setembro/2017.

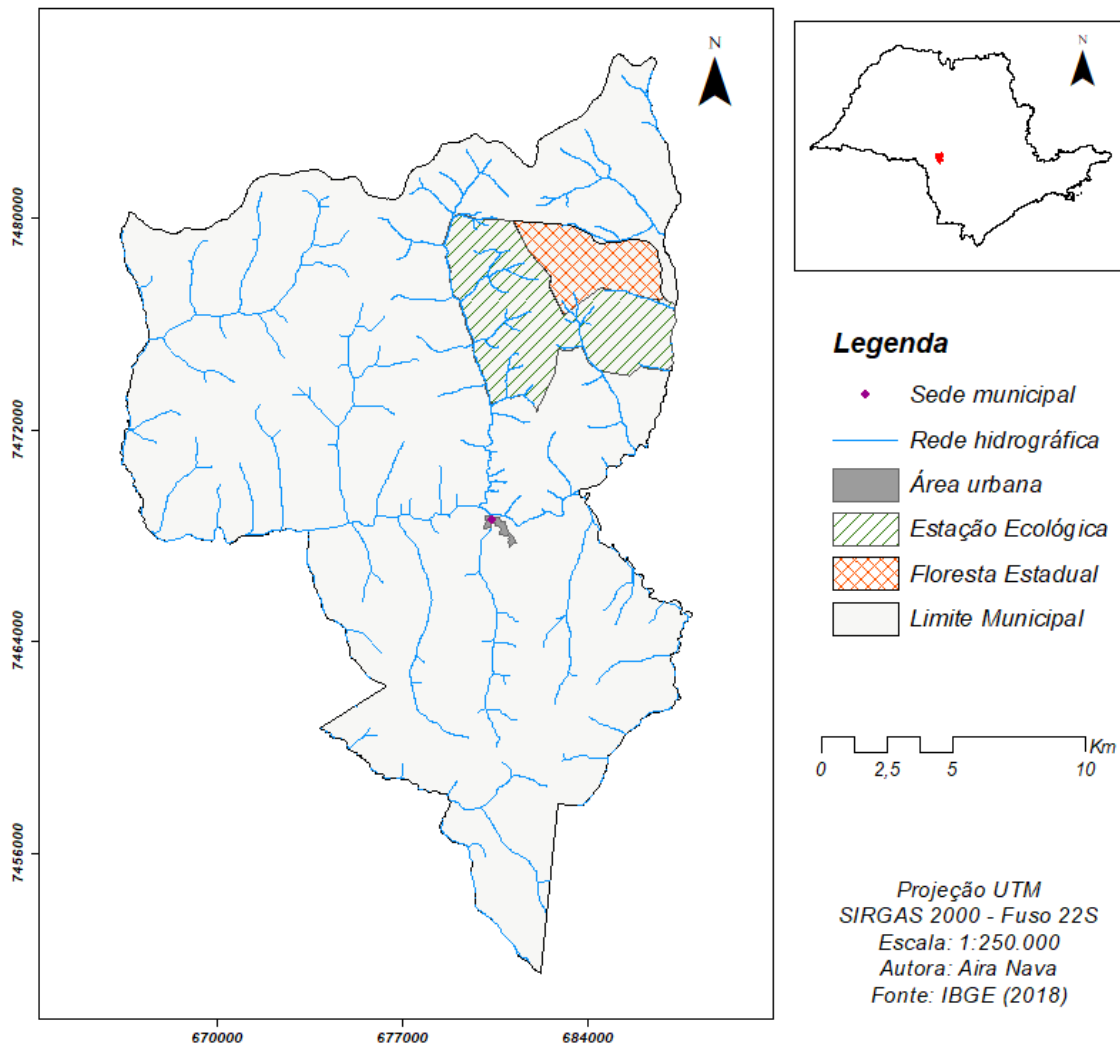
3.1 Caracterização da área de estudo

Os pontos de coleta de dados se encontram inseridos na Estação Ecológica de Santa Bárbara (EEcSB) e na Floresta Estadual de Santa Bárbara (FESB). Essas unidades de conservação (UC) constituem a área de estudos.

A EEcSB está localizada no município de Águas de Santa Bárbara, no Estado de São Paulo. Segundo o Instituto Florestal – IF (2011), a UC foi estabelecida por meio do Decreto Estadual nº 22.337, de 7 de junho de 1984, o qual além de especificar seus limites e determinar o IF como o responsável pela sua instalação e administração, também a delimitou como uma área de 2.712 ha situada dentro dos limites da Floresta Estadual de Santa Bárbara. Na área transformada em Estação Ecológica, a vegetação nativa (cerrado, brejos e mata de galeria) divide espaço com o reflorestamento de pinus e eucalipto.

A Floresta Estadual de Santa Bárbara (FESB) foi criada pelo Decreto Estadual nº 44.305, de 30 de dezembro de 1964. Resultante da desapropriação da Fazenda Santana, que utilizava o local para pecuária extensiva, atualmente, ocupa uma área de 1.659 ha e tem como objetivo a pesquisa científica e o uso sustentável dos recursos naturais (IF, 2011). A Figura 13 mostra a localização da EEcSB e da FESB.

Figura 13 - Localização da EEcSB e da FESB no município de Águas de Santa Bárbara - SP

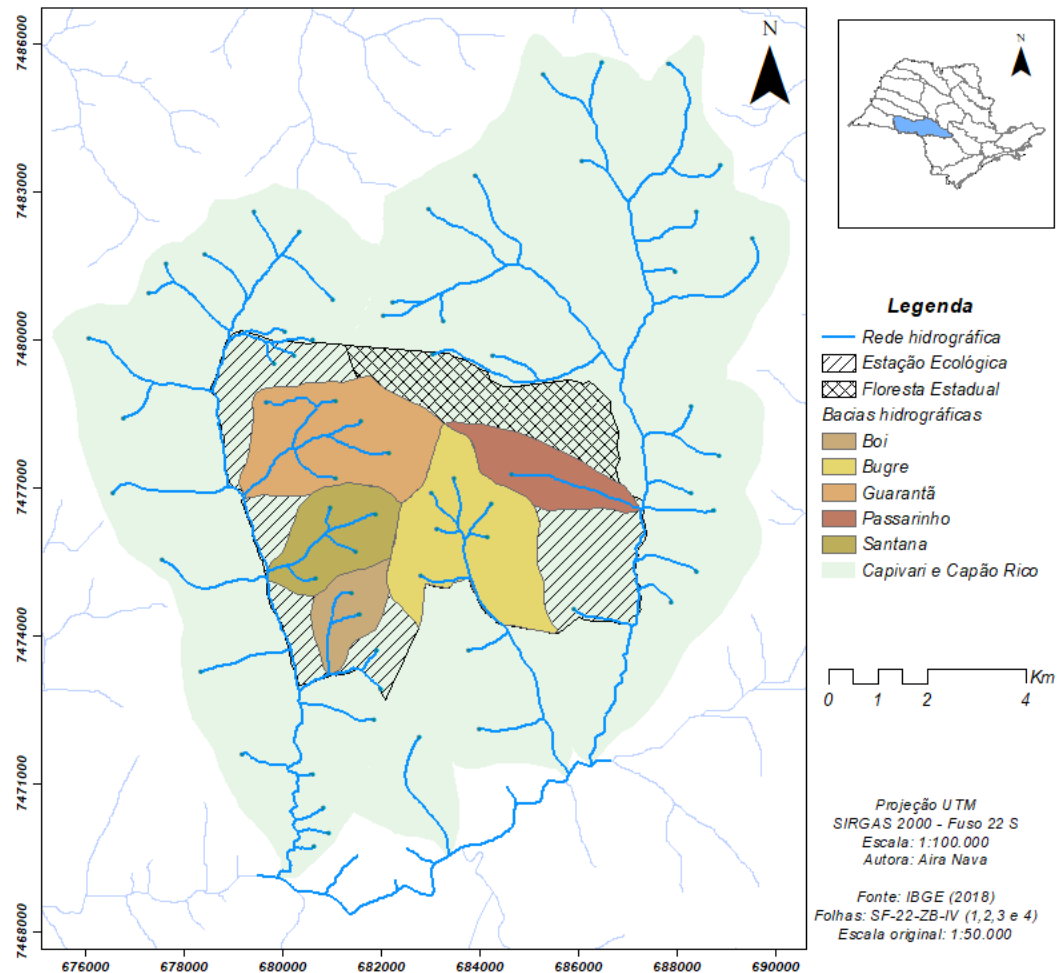


A área de estudo, composta por essas unidades de conservação, pertence à unidade hidrográfica do Rio Pardo, integrante da bacia hidrográfica do Rio Paranapanema, Unidade de Gerenciamento de Recursos Hídricos 17, Médio Paranapanema (UGRHI 17 – MP). O local é delimitado a leste pelo Rio Capão Rico e a oeste pelo Rio Capivari, ambos com as nascentes em propriedades particulares a montante. Em seu interior é possível encontrar nascentes de muitos corpos hídricos, o que assegura sua a função de proteção às águas superficiais (HONDA; NIZOLI, 2005).

A Figura 14, área de estudos, mostra as bacias dos rios Capivari e Capão Rico e as bacias dos rios nos quais estão localizados os pontos de coleta de informações de

águas subterrâneas e de solo, sendo eles Guarantã, Santana, Boi, Água do Bugre e Passarinho.

Figura 14 – Área de estudos com a rede de drenagem da EEcSB e FESB



As unidades de conservação se encontram em uma zona de contato entre os biomas do Cerrado (savana) e da Mata Atlântica (floresta tropical), ambos incluídos entre os *hotspots* globais para a conservação. Isso garante ao local grande importância, uma vez que áreas ecotonais são reconhecidas por sua maior diversidade e por sua relevância na dinâmica de grandes tipos vegetacionais em períodos de mudanças climáticas (DURIGAN; RATTER, 2006).

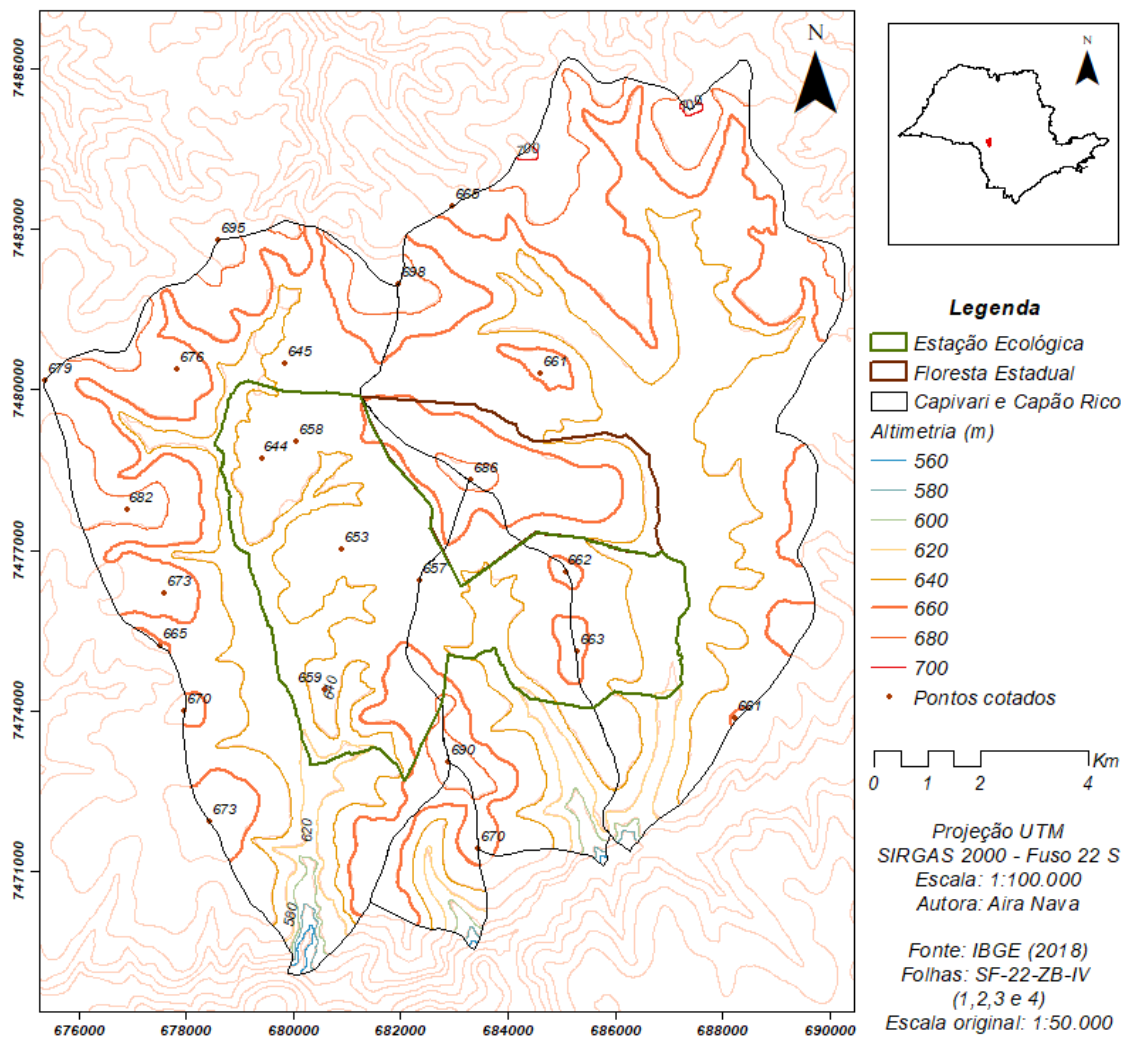
A área está inserida sob a classificação climática Cw de Köppen, que abrange toda a parte central do Estado e é caracterizada pelo clima tropical de altitude, com chuvas no verão e seca no inverno. A temperatura média do mês mais frio é cerca de 18°C e a do mês mais quente pode ultrapassar 22°C. A precipitação pluviométrica anual oscila entre 1000 e 1300 mm, evidenciando a sazonalidade climática entre o

período seco (de junho a setembro) e o período chuvoso (de dezembro a fevereiro) (CEPAGRI, 2015).

Segundo o Instituto de Pesquisas Tecnológicas (1981), a região está localizada na Zona de Áreas Indivisas da Província do Planalto Ocidental cuja estrutura do relevo é dada por camadas sub-horizontais, com leve caimento para oeste, o que forma uma extensa plataforma estrutural bastante suavizada. O relevo é predominantemente do tipo colinoso e com baixas declividades (<15%).

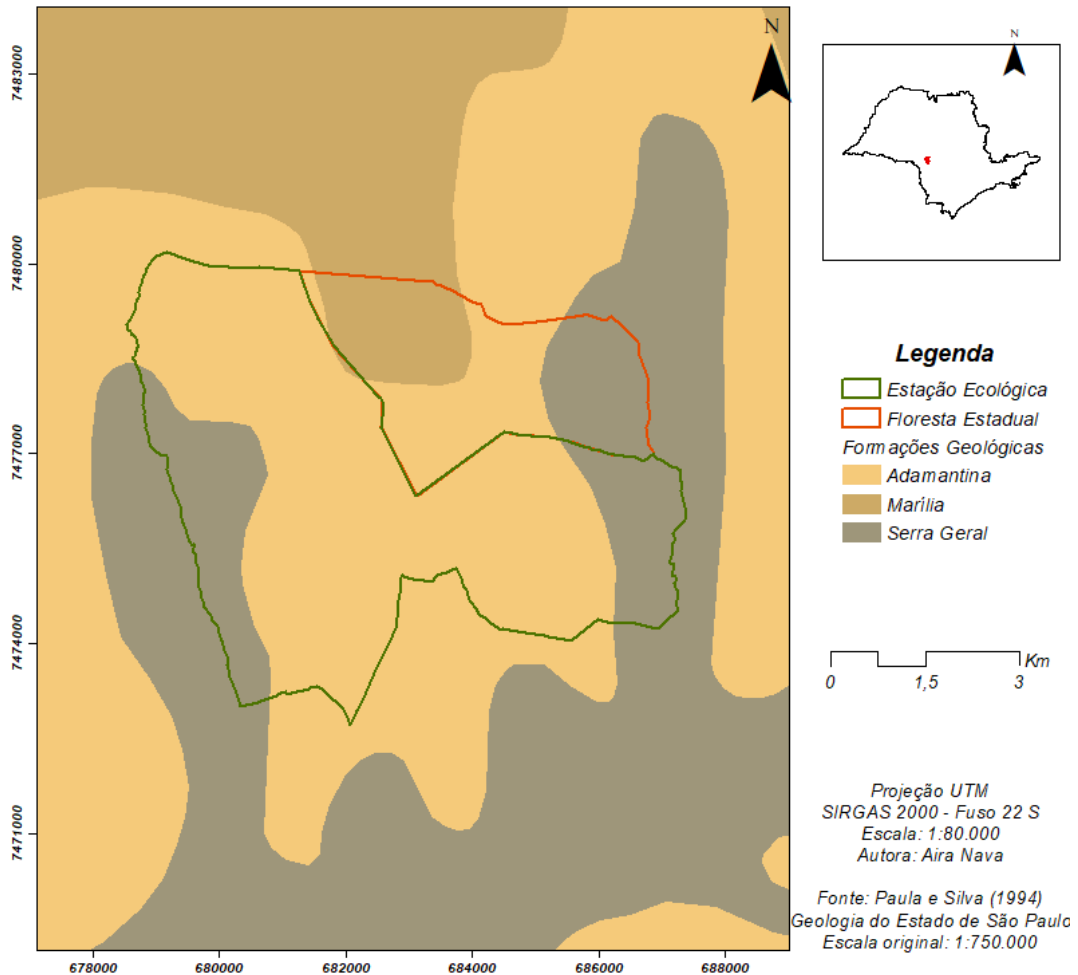
A altimetria nas proximidades da área de estudo varia entre 560 e 700 m (Figura 15), sendo possível encontrar relevos de morrotes alongados e espigões, “onde predominam interflúvios sem orientação preferencial, topos angulosos e achatados, vertentes ravinadas, com perfis retilíneos, drenagem de média a alta densidade, padrão dendrítico e vales fechados”, em contraposição ao relevo colinoso predominante na região (SIGRH, 2018).

Figura 15 - Altimetria das bacias hidrográficas dos rios Capivari e Capão Rico



A área está situada na Bacia Sedimentar do Paraná, onde afloram os sedimentos das Formações Adamantina e Marília do Grupo Bauru e as rochas ígneas extrusivas basálticas da Formação Serra Geral do Grupo São Bento (IPT, 1981) (Figura 16).

Figura 16 - Formações geológicas na região da EEcSB e FESB



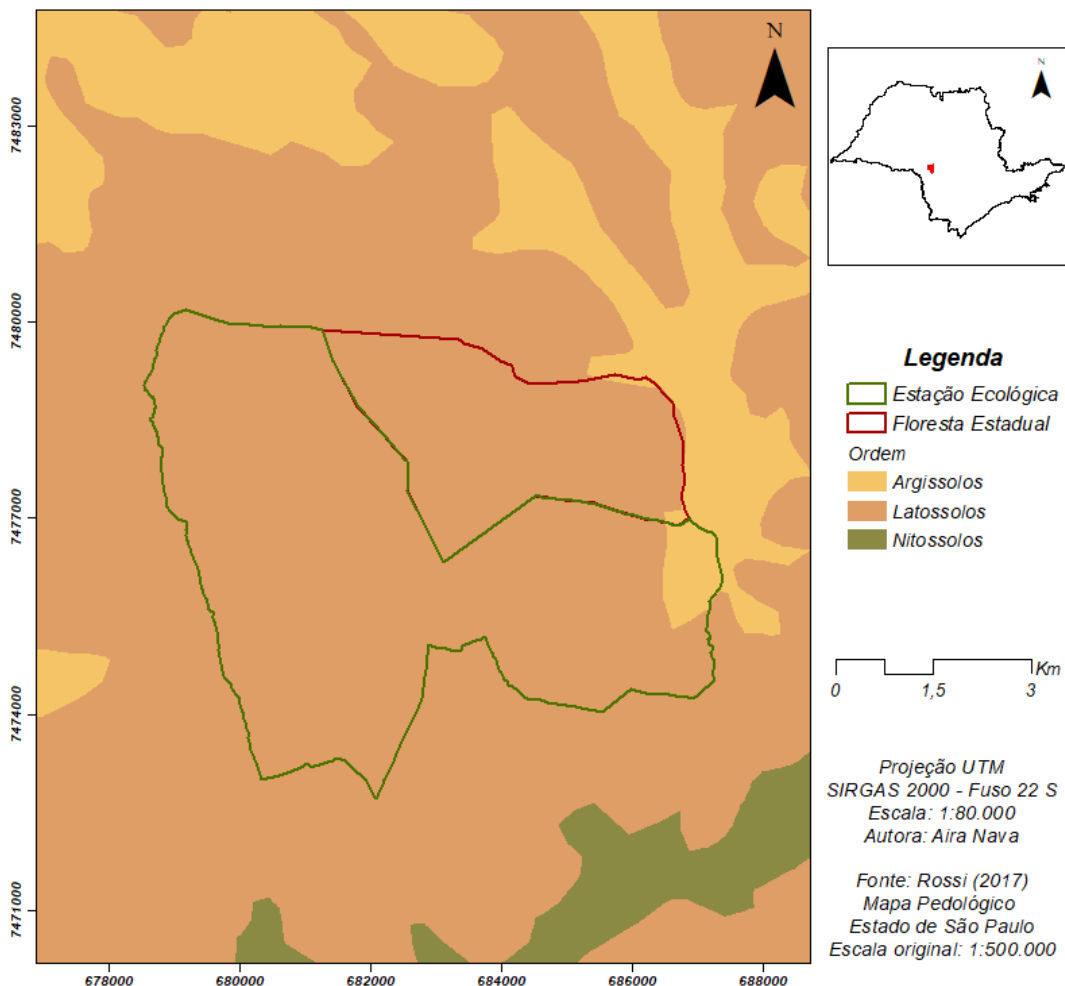
De acordo com Paula e Silva et al. (1994), a Formação Adamantina aflora em vasta extensão no oeste do Estado de São Paulo, recobrendo as unidades pretéritas do Grupo Bauru (formações Caiuá e Santo Anastácio) e da Formação Serra Geral, estando recoberta apenas pela Formação Marília no compartimento centro-oriental da bacia. Com depósitos continentais de origem fluvial, a formação Adamantina, em superfície, caracteriza-se pela presença de arenitos avermelhados a acastanhados, finos a muito finos, argilosos, intercalados por lamito marrom a avermelhado, arenoso, carbonático.

A Formação Marília é composta predominantemente por arenitos grossos, com teor de matriz variável, maciços ou com acamamento incipiente e com raras

estratificações cruzadas de médio porte e camadas descontínuas de lamitos vermelhos e calcários. A Formação Serra Geral, província magmática relacionada aos derrames e intrusivas que recobrem a Bacia do Paraná, é constituída predominantemente por basaltos e basalto-andesitos de filiação toleítica (SOARES et al, 1980; PAULA E SILVA et al, 2005; CPRM, 2018).

O solo predominante no local é o Latossolo Vermelho (LV), de grande interesse para o manejo. No entorno da área, também ocorrem os Argissolos Vermelho-Amarelos (PVA) e, acompanhando a faixa de drenagem do Rio Pardo, os Nitossolos Vermelhos (NV) (IF, 2011), conforme a Figura 17.

Figura 17 - Mapa de solos na região da EEcSB e FESB



3.1.1 Sistema Aquífero Bauru (SAB)

A área de estudos se encontra sobre o SAB que ocupa uma área de aproximadamente 97 Km², parcela que corresponde a cerca da metade da extensão

oeste do Estado de São Paulo. As rochas sedimentares (arenosas, areno-argilosas e siltosas dos Grupos Bauru) que compõem o aquífero estão dispostas sobre o basalto da Formação Serra Geral (SILVA; CHANG, 2010).

De acordo com Mancuso e Campos (2005), o SAB apresenta uma espessura média de 75 metros. Essa espessura varia em virtude da forma irregular do topo do basalto e pode atingir valores superiores a 300 metros. As águas do SAB ocorrem regionalmente de forma livre podendo se apresentar, localmente, na forma semiconfinada ou confinada. O sentido do escoamento regional é dado em direção às drenagens principais dos rios Turvo, Preto, São José dos Dourados, Tietê, Aguapeí, Peixe e Santo Anastácio, Paraná e Paranapanema, principais exutórios do sistema.

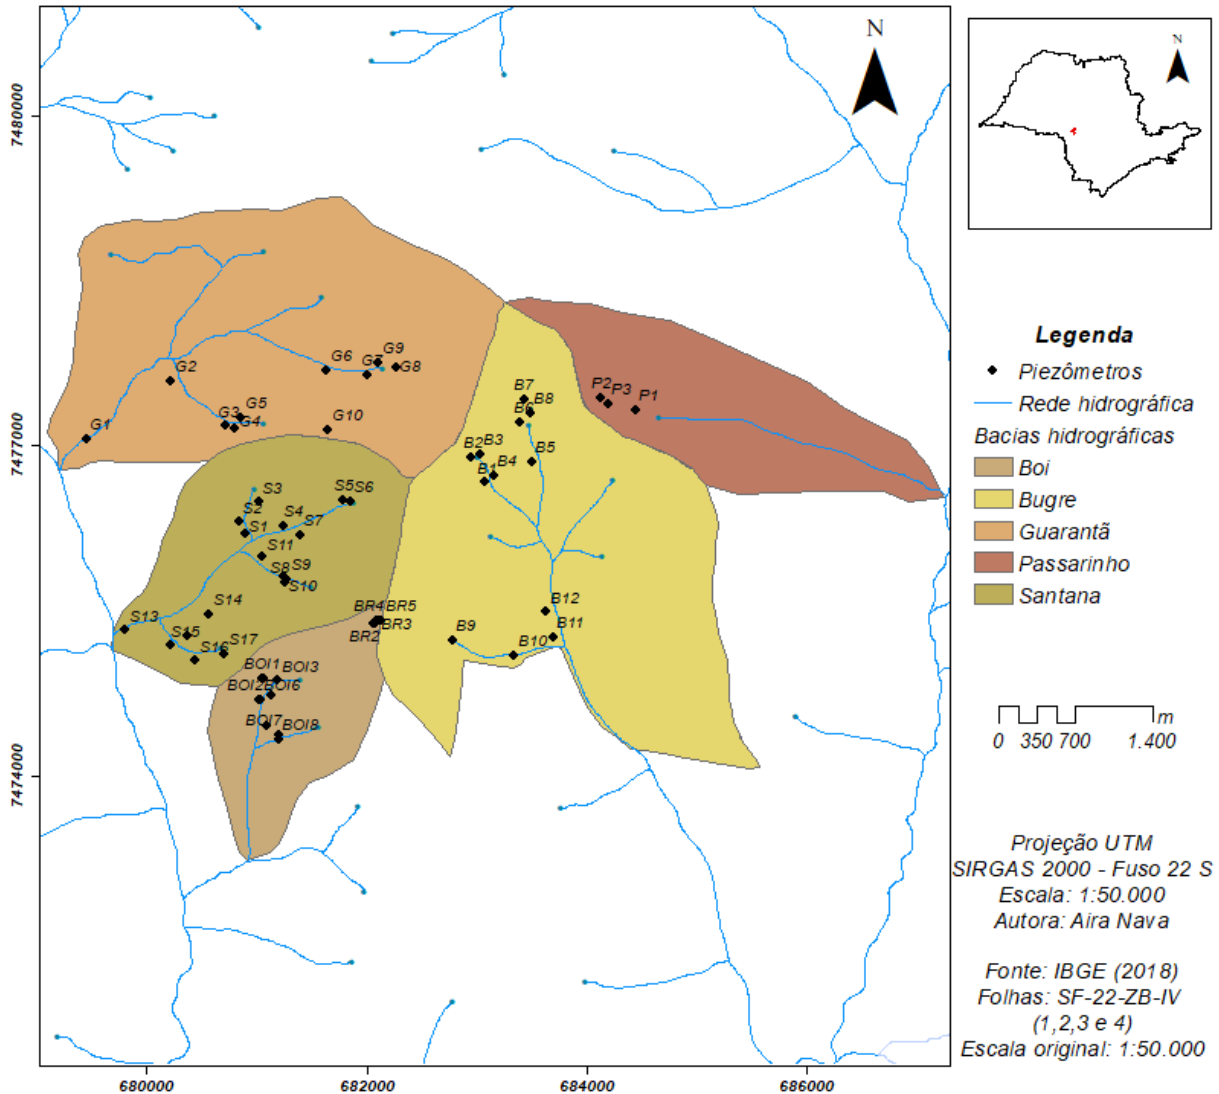
A produtividade do SAB é considerada de média a alta, porém, é variável ao longo de sua extensão. Enquanto suas porções norte, leste e sudeste, apresentam suas capacidades diminuídas devido aos arenitos intercalados por camadas de sedimentos de granulometria fina (lamitos e siltitos), ou possuem uma cimentação de mineral carbonático entre os grãos de areia; as porções inferiores e oeste mostram uma melhor produtividade, pois apresentam um predomínio de arenitos com baixo teor de material fino, conforme apontado em estudo realizado pelo DAEE/IG/IPT/CPRM (2005).

Segundo Silva et al. (2005), as águas do aquífero são, em geral, de boa qualidade para o consumo humano. O SAB é utilizado por cerca de duzentos e quarenta municípios paulistas, sendo que destes, 87% são abastecidos integralmente por águas subterrâneas.

3.2 Poços de monitoramento das águas subterrâneas

As informações relacionadas aos níveis de água subterrânea foram obtidas por meio do monitoramento de 56 piezômetros instalados nas bacias hidrográficas do Guarantã, Santana, Boi, Bugre e Passarinho, conforme a Figura 18. A série histórica de onde os valores foram extraídos teve início em 7/03/2016 e foi finalizada em 10/09/2017. A temperatura da água foi coletada no dia 05/09/2017.

Figura 8 - Localização dos poços de monitoramento das águas subterrâneas



A infraestrutura e as medições desses poços de monitoramento são frutos do financiamento da Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP ao Processo 2014/04524-7, intitulado de “Monitoramento de níveis freáticos no Sistema Aquífero Bauru em área de conservação em Águas de Santa Bárbara, SP”.

3.3 Material

3.3.1 Base cartográfica

Para o levantamento do material cartográfico, foram utilizadas as cartas topográficas do Instituto Brasileiro de Geografia e Estatística – IBGE cuja escala é de

1:50000, com equidistância de 20 metros entre as curvas de nível. A área de estudos (EEcSB, FESB e as bacias nas quais se encontram) está inserida nas Folhas SF-22-Z-B-IV 1,2,3 e 4 que representam os municípios de Domélia, Turvinho, Óleo e Santa Bárbara do Rio Pardo, respectivamente.

3.3.2 Imagens Orbitais

Para extrair as informações relativas aos índices de vegetação e de umidade da área foram utilizadas as imagens do satélite Landsat 8, com base nas bandas espectrais 4, 5 e 6 do sensor OLI (*Operational Land Imager*), Quadro 1. As imagens foram obtidas do site *Earth Explorer* do *United States Geological Survey* - USGS (<https://earthexplorer.usgs.gov/>). O Landsat 8 apresenta uma resolução temporal de 16 dias e a data da passagem do satélite sobre a área, neste estudo, ocorreu em 10 de setembro de 2017.

Quadro 1 - Características do satélite Landsat 8

Sensor	Bandas Espectrais	Significado	Resolução Espectral (μm)	Resolução Espacial (m)
OLI (<i>Operational Land Imager</i>)	B4	Vermelho	0,63 - 0,68	30
	B5	infravermelho próximo (NIR)	0,84 - 0,88	
	B6	infravermelho médio (SWIR 1)	1,56 - 1,66	

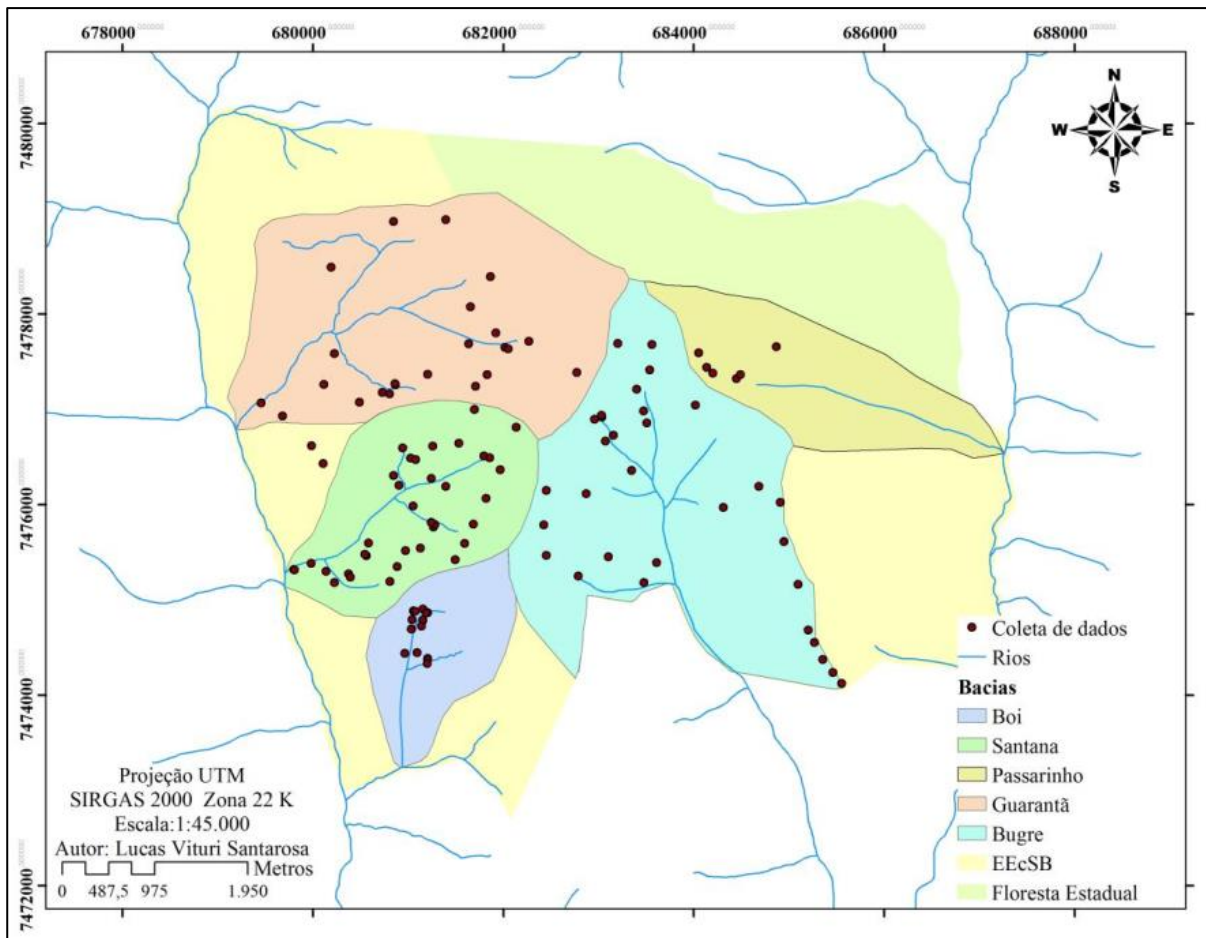
Fonte: USGS (2018).

3.3.3 Amostragem de solo

Os dados referentes aos atributos físicos dos solos foram obtidos por meio do trabalho realizado por Santarosa (2016). A malha amostral do levantamento consistiu em 113 pontos distribuídos irregularmente nas bacias estudadas (Figura 19).

As amostras foram coletadas aproximadamente em 50 cm de profundidade, segundo Santos et al. (2005) e encaminhadas para o laboratório de Geologia, Pedologia e Geomorfologia da UNESP, campus experimental de Ourinhos/SP, para a análise granulométrica conforme a metodologia fornecida pela Embrapa (1997).

Figura 19 - Localização dos pontos amostrais de solo na EEcSB e FESB



Fonte: SANTAROSA (2016).

Além da textura dos solos (Areia, Argila e Silte em %), também foram utilizadas, a partir do mesmo levantamento, as medidas de condutividade hidráulica (K em m/dia) e de resistência do solo a penetração (kPa). Os valores de condutividade hidráulica foram estabelecidos por meio de uma adaptação do método de Hazen (FETTER, 2001), estimada com base na granulometria, a partir do diâmetro efetivo das partículas do solo. A resistência à penetração foi obtida com o aparelho eletrônico da marca FALKER, modelo SoloTrack PLG5300, após três repetições para cada medição a fim de excluir os efeitos de interferências locais, como raízes e cascalho, realizadas por Santarosa (2016).

3.3.4 Programas

Para os cálculos das componentes principais e para o ajuste do modelo de Regressão Linear Múltipla foi utilizado o programa Minitab 16 (MINITAB INC., 2018).

Para a geração das variáveis relativas ao relevo e a vegetação foram utilizados os programas SAGA-GIS 2.2.2 (SAGA GIS DEVELOPMENT TEAM, 2016) e ArcGIS v 10.3 (ESRI, 2016). O ArcGis v. 10.3 também foi utilizado no georreferenciamento das cartas topográficas, processamento de imagens orbitais, vetorização e finalização dos mapas.

A correção atmosférica das imagens foi realizada com o QGIS v. 2.14.8 (QGIS DEVELOPMENT TEAM, 2016) por meio do plug-in Semi-Automatic Classification Plugin – SCP (CONGEDO, 2016), que utiliza o método da Subtração do Objeto Escuro 1 (DOS1), um dos mais tradicionais para a redução da influência atmosférica, segundo OSCO et al. (2017).

O semivariograma e a krigagem ordinária foram elaborados no programa ArcGis v. 10.3 (ESRI, 2016).

3.4 Métodos

3.4.1 Índices de vegetação

a) O Índice de Vegetação por Diferença Normalizada – **NDVI** (*Normalized Difference Vegetation Index*): segundo Ponzoni e Shimabukuro (2010), vem sendo amplamente aplicado em diferentes estudos climáticos, florestais e de culturas agrícolas. Proposto por Rouse et al. (1973), é calculado pela diferença de reflectância entre a faixa do infravermelho próximo e a faixa de vermelho visível. A normalização é feita pela Equação 11:

$$NDVI = \frac{(\rho_{IV} - \rho_V)}{(\rho_{IV} + \rho_V)} \quad (11)$$

Onde: ρ_{IV} corresponde ao fluxo radiante refletido no infravermelho próximo e ρ_V ao fluxo radiante refletido no vermelho da região do visível.

O valor deste índice varia entre -1 e 1. De acordo com Liu (2006), os valores negativos representam as nuvens, os valores ao redor de zero representam solo nu ou sem vegetação e os valores positivos representam a vegetação. O valor de NDVI mais alto indica o maior grau de verde da superfície, podendo ser usado para inferir sobre uma vegetação mais densa ou em pleno vigor de crescimento.

A reflectância da faixa do infravermelho próximo não ultrapassa 0,55 e a do vermelho visível não ultrapassa 0,5, fazendo com que o valor máximo de NDVI seja de 0,84 (LIU, 2006). Desta forma, para alvos terrestres o limite inferior é de aproximadamente 0 e o limite superior é de aproximadamente 0,80 (PONZONI; SHIMABUKURO, 2010). O NDVI é resultado da combinação de duas bandas e isso faz com que os efeitos de presença dos constituintes da atmosfera e das perturbações radiométricas e geométricas sejam parcialmente encobertos (HOLBEN, 1986).

b) O Índice de Vegetação Ajustado ao Solo – **SAVI** (*Soil Adjusted Vegetation Index*): proposto por Huete (1988), introduz um novo fator ao NDVI para incorporar o efeito da presença do solo, uma vez que este exerce influência no espectro da vegetação vindo de dosséis vegetais esparsos e no cálculo de índices de vegetação (LIU, 2006). O SAVI é calculado pela Equação 12:

$$SAVI = \frac{(1+L)(\rho_{IV}-\rho_V)}{(\rho_{IV}+\rho_V+L)} \quad (12)$$

O fator L é a constante que minimiza o efeito do solo, variando de 0 a 1 (HUETE, 1988). No estudo, utilizou-se o valor de 0,50 que corresponde a cobertura média da vegetação. Para Ponzoni e Shimabukuro (2010), o SAVI limita-se em função dos diferentes biomas e situações agrícolas, uma vez que os valores da constante são generalizados e não consideram as especificidades dos ambientes analisados, apenas a densidade vegetada.

c) O Índice de Umidade por Diferença Normalizada – **NDWI** (*Normalized Difference Moisture Index*): proposto por Gao (1996), fornece informações sobre o conteúdo de umidade interno à vegetação, sendo relacionado ao teor de água na folha, mostra-se menos sensível às variações da atmosfera quando comparado ao NDVI.

O índice é obtido por meio da razão entre a diferença das refletividades do infravermelho próximo (ρ_{IV}) e do infravermelho médio (ρ_{MIR}) e a soma das mesmas, conforme a Equação 13:

$$NDWI = \frac{\rho_{IV}-\rho_{MIR}}{\rho_{IV}+\rho_{MIR}} \quad (13)$$

O valor de NDWI varia entre -1 e 1, onde os valores negativos representam áreas com vegetação seca e os valores positivos áreas com vegetação verde.

Segundo Ji et al. (2009), a concepção de um índice espectral de água se baseia no fato de que a absorção da água ocorre no infravermelho próximo e em comprimentos de ondas curtas do infravermelho. A operação aritmética além de aperfeiçoar os sinais espectrais pelo contraste entre os diferentes comprimentos de onda, também anula uma grande parte dos componentes de ruído, comuns em regiões de comprimentos de onda diferentes (isto é, a calibração do sensor e mudanças nas condições de radiação causada pela iluminação, solo, topografia, condições atmosféricas, entre outros).

d) O Índice de Vegetação Realçado – **EVI2** (*Enhanced Vegetation Index*): proposto por Jiang et al. (2008), foi desenvolvido para otimizar o sinal de resposta da vegetação, aperfeiçoando a sensibilidade em regiões com maiores densidades de biomassa. Embora seja equivalente ao EVI (HUETE et al., 2002), no EVI2 não há inclusão da banda espectral na faixa do azul, cuja função é minimizar ruídos e incertezas associados a presença de aerossóis na atmosfera. É calculado segundo a Equação 14:

$$EVI2 = 2,5 \frac{\rho_{IV} - \rho_V}{(\rho_{IV} + (2,4 * \rho_V) + 1)} \quad (14)$$

Onde: ρ_{IV} é a reflectância na banda do infravermelho próximo; ρ_V é a reflectância na banda do vermelho; 2,5 é um fator de ganho; 2,4 é um coeficiente de ajuste para o efeito de aerossóis na atmosfera e 1 é um fator de ajuste do solo.

De acordo com Latorre et al. (2007), os valores de EVI2 variam entre 0 (vegetação menos densa) e 1 (vegetação mais densa). O índice possibilita um melhor monitoramento da vegetação a partir de uma ligação do sinal de fundo do dossel e a redução das influências atmosféricas.

e) Índice Topográfico de Umidade – **ITU** (*Topographic Wetness Index*): desenvolvido por Beven e Kirkby (1979) para aplicação em modelo hidrológico, é calculado segundo a Equação 15:

$$ITU = \ln\left(\frac{Ac}{\tan\beta}\right) \quad (15)$$

Onde: Ac é a área de contribuição ao pixel (m^2) e β é a declividade de cada pixel (radianos).

O ITU reflete a tendência de acúmulo de água no solo e está diretamente relacionado à área de contribuição e inversamente à declividade. Seus valores variam de -3 a 30 (BALLERINE, 2017).

3.4.2 Obtenção do Modelo Digital de Elevação (MDE) e da declividade

Os atributos topográficos fornecem descrições numéricas do terreno e são classificados como atributos primários e secundários. Atributos topográficos primários são aqueles baseados em parâmetros morfométricos como declividade, aspecto, elevação e direção de fluxo. Os dados primários podem ser obtidos diretamente de dados topográficos digitais usando métodos automatizados. Atributos secundários (também conhecidos como atributos compostos) são derivados de atributos primários ou formados pela combinação de atributos primários com outras variáveis de paisagem (e/ou ambientais). Um exemplo de atributo secundário é a variabilidade espacial da umidade do solo ou a distribuição do conteúdo de água no solo (Moore et al., 1991).

O MDE foi obtido com base nas informações planialtimétricas digitalizadas (curvas de nível, pontos cotados e hidrografia) a partir da carta topográfica, na escala 1:50.000. A interpolação dos dados para o MDE foi realizada por meio da ferramenta *Topo to Raster* disponibilizada no programa ArcGis v.10.3.

A ferramenta *Topo to Raster* resulta em um modelo hidrológicamente consistente, pois considera as informações contidas nos dados de ponto, linha e polígono. A possibilidade de inserir linhas de drenagem garante a integridade do terreno na direção do fluxo e busca a remoção de pixels espúrios ou que interrompem o fluxo ao longo da rede hidrográfica. Essas operações durante o processo de interpolação

produzem um modelo mais suave e com uma precisão consideravelmente aumentada (HUTCHINSON, 1989; SAITO et al., 2012). Na etapa de pós-processamento, as depressões espúrias remanescentes (*sinks*) resultantes do processo de interpolação foram identificadas e corrigidas pela ferramenta *Fill*.

Por meio da ferramenta *Slope* e utilizando o raster gerado para o MDE como entrada, foi possível calcular a declividade da área. O cálculo da declividade no SIG é realizado com base nos valores altimétricos dos pixels adjacentes, pela técnica da média máxima dos gradientes de altitude, nas direções X e Y (Carvalho, 2016).

3.4.3 Análise de componentes principais e modelo de regressão linear múltiplo

Para realizar a PCA, os poços com dados faltantes foram retirados (total de 9 poços). Na maioria das situações, a ausência dos dados ocorreu nos diagnósticos das características físicas do solo em virtude da dificuldade de coleta em alguns pontos da área.

Conforme proposto por Cruz et al. (2012) e Savi (2017), as porcentagens das variâncias dos fatores foram somadas até se atingir um valor mínimo de 70%, a partir disso as componentes foram descartadas. Esse intervalo de porcentagem é determinado de modo que o conjunto de fatores selecionados explique uma variabilidade mínima do global.

Com base no grupo de componentes principais, as variáveis ambientais com maior relevância foram selecionadas a partir dos coeficientes com maiores valores das funções PCA.

Com isso, avaliou-se a significância das variáveis explicativas encontradas na PCA para o modelo de regressão linear múltiplo (sendo o valor $p < 5\%$). O ajuste do modelo foi avaliado pelo coeficiente de determinação e R^2 predito. A avaliação do modelo pode ser visualizada nos gráficos e histogramas do item 4.4.

3.4.4 Ajuste do modelo de predição e avaliação do semivariograma

A validação do modelo de predição foi realizada segundo a validação cruzada. Para a seleção dos modelos, além do ME (Equação 16) e do RMSS (Equação 17), foram considerados aqueles que apresentaram valores da média do erro padronizado

(MEP) próximos de 0 (Equação 18) e aqueles com os menores valores para a raiz do erro médio quadrático (RMSE), conforme a Equação 19.

$$ME = \frac{1}{n} \sum_{i=1}^n [\hat{Z}(x_i) - Z(x_i)] \quad (16)$$

$$RMSS = \sqrt{\frac{\sum_{i=1}^n (\hat{Z}(x_i) - Z(x_i))^2}{n}} \quad (17)$$

$$MEP = \frac{\sum_{i=1}^n [\hat{Z}(x_i) - Z(x_i)] / \hat{\sigma}(x_i)}{n} \quad (18)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n [(\hat{Z}(x_i) - Z(x_i)) / \hat{\sigma}(x_i)]^2}{n}} \quad (19)$$

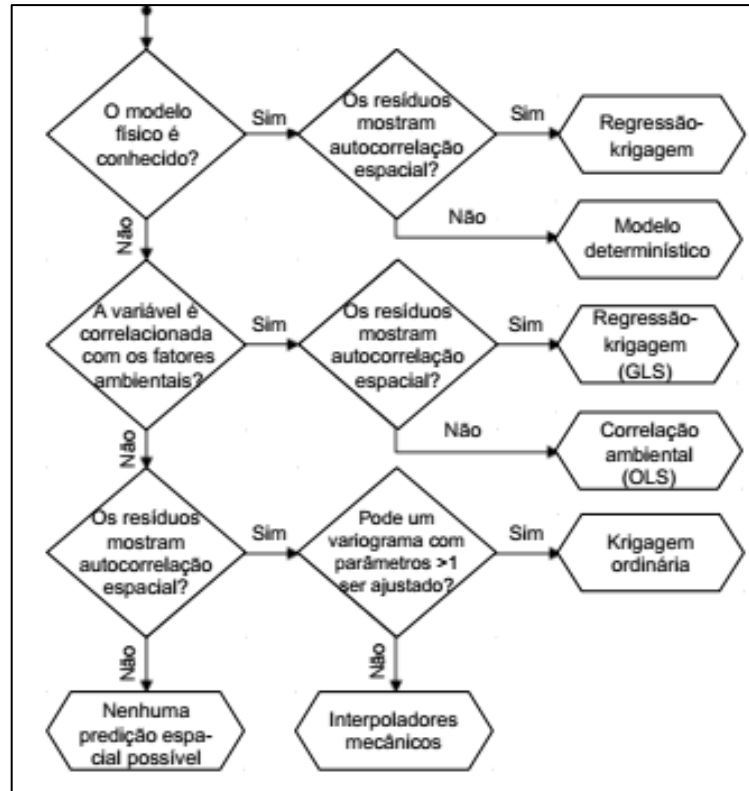
Onde n é o número de pontos de validação; \hat{Z}_{x_i} é o valor estimado do atributo e Z_{x_i} é o valor obtido por medição.

Os semivariogramas foram considerados isotrópicos e os modelos para os níveis preditos e para os resíduos da regressão foram definidos segundos os parâmetros patamar, efeito pepita e alcance. Com o valor do *lag* estabelecido para o semivariograma experimental, foi possível selecionar um modelo teórico ao semivariograma por meio da análise visual da curva teórica. Após o ajuste dos modelos, os valores dos dados de níveis estimados e dos resíduos foram interpolados pela krigagem ordinária.

3.4.5 Elaboração do modelo de regressão-krigagem

A seleção do modelo RK aos dados foi baseada em algumas premissas apresentadas por Hengl (2009) cujas avaliações incluíram, por exemplo, o ajuste do modelo determinístico, a correlação entre as variáveis e a autocorrelação dos resíduos da regressão. A Figura 20 mostra uma árvore de decisões para a escolha do modelo de predição mais adequado.

Figura 20 - Árvore de decisão para a seleção do modelo de predição espacial



Fonte: HENGL (2009), traduzido pela autora.

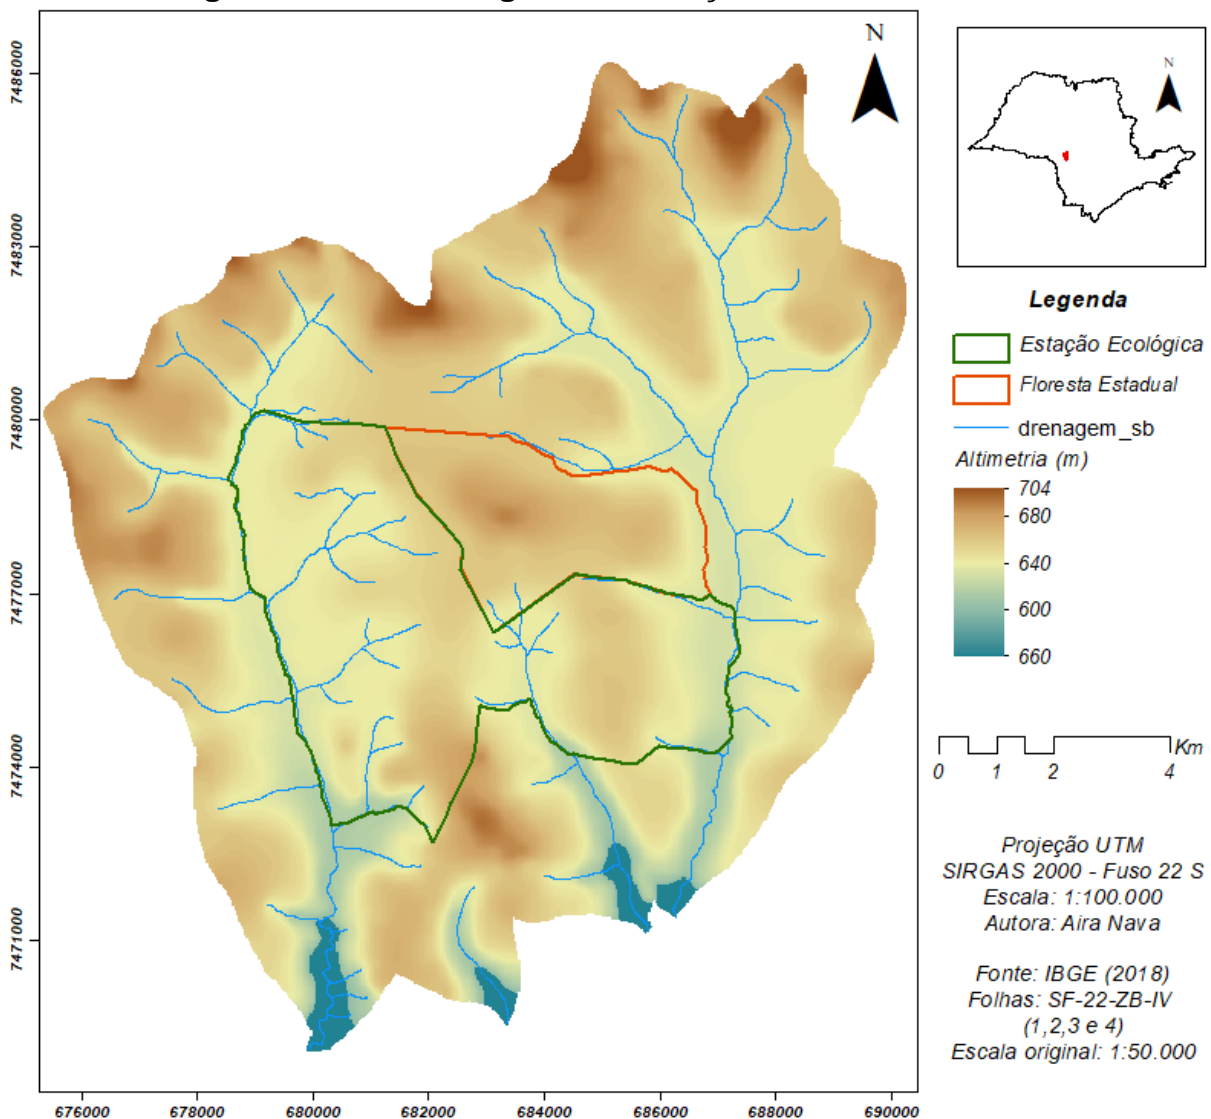
4 RESULTADOS E DISCUSSÃO

4.1 Levantamento de variáveis ambientais

4.1.1 Variáveis do terreno

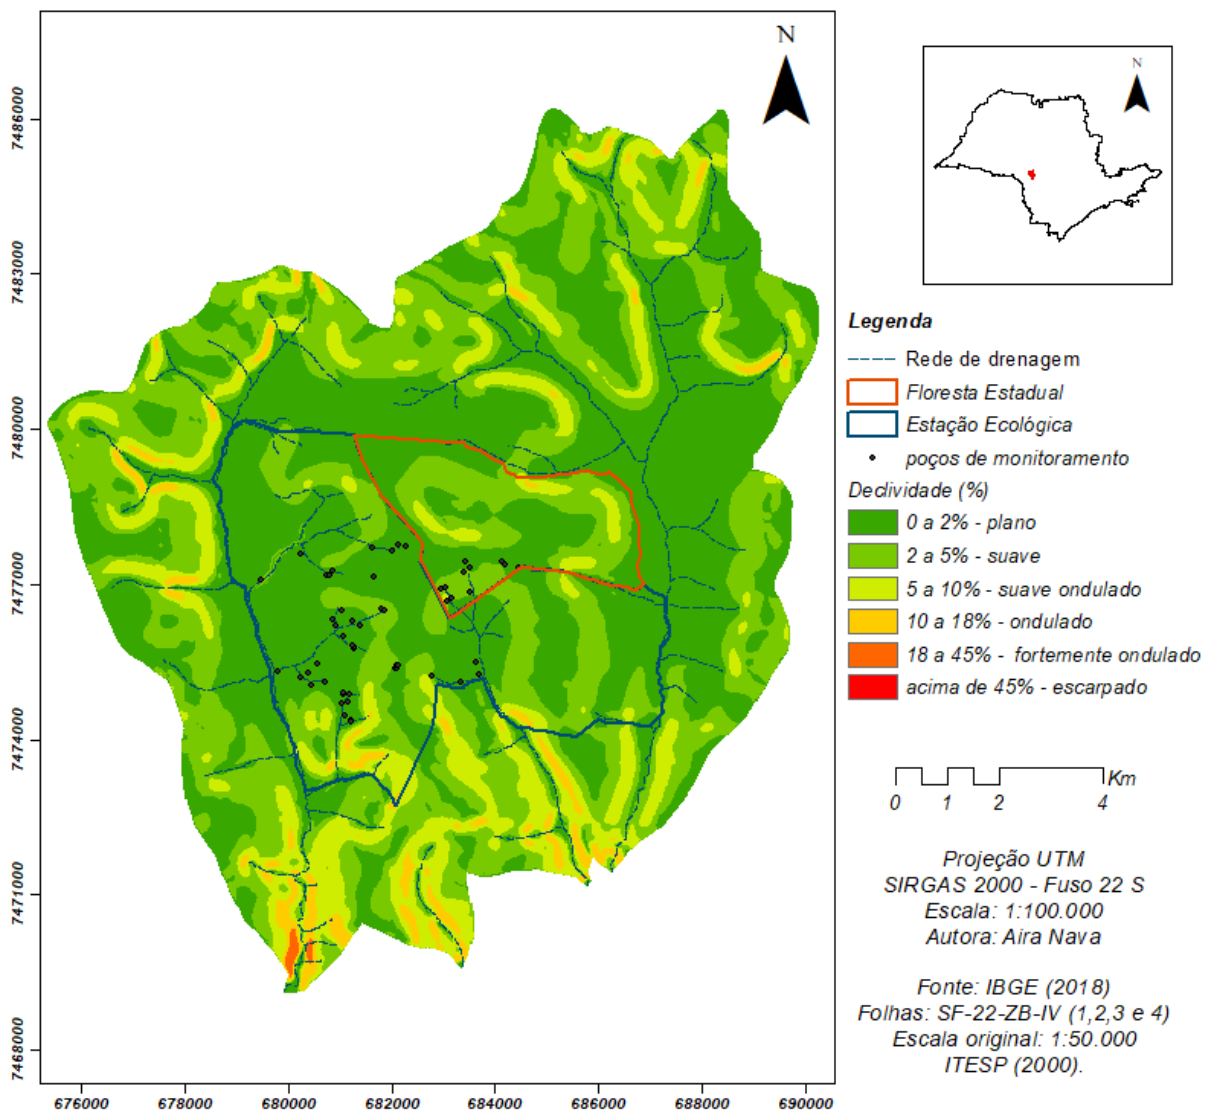
Uma vez que as características topográficas influenciam nos fluxos de água subterrânea, conforme demonstrado por Condon e Maxwell (2015), e nos processos de escoamento e infiltração, buscou-se analisar as condições nas quais os poços se encontram. O MDE (Figura 21) mostrou que a altimetria dentro das áreas de estudos (Estação Ecológica e Floresta Estadual) varia de forma uniforme entre 620 e 680 metros. A partir desses valores, obteve-se as variáveis declividade e ITU.

Figura 21 - Modelo Digital de Elevação da área de estudo



De acordo com a classificação do ITESP (2000), o relevo predominante na área varia de suave a plano, Figura 22. Dentro dos limites das áreas de proteção, o valor da declividade permanece entre 0% a 12%. De modo geral, declives acentuados favorecem o escoamento superficial direto, diminuindo a infiltração. Superfícies suavemente onduladas permitem o escoamento superficial menos veloz e aumentam a possibilidade de infiltração (KARMANN, 2003).

Figura 22 – Declividade (%) da área de estudo

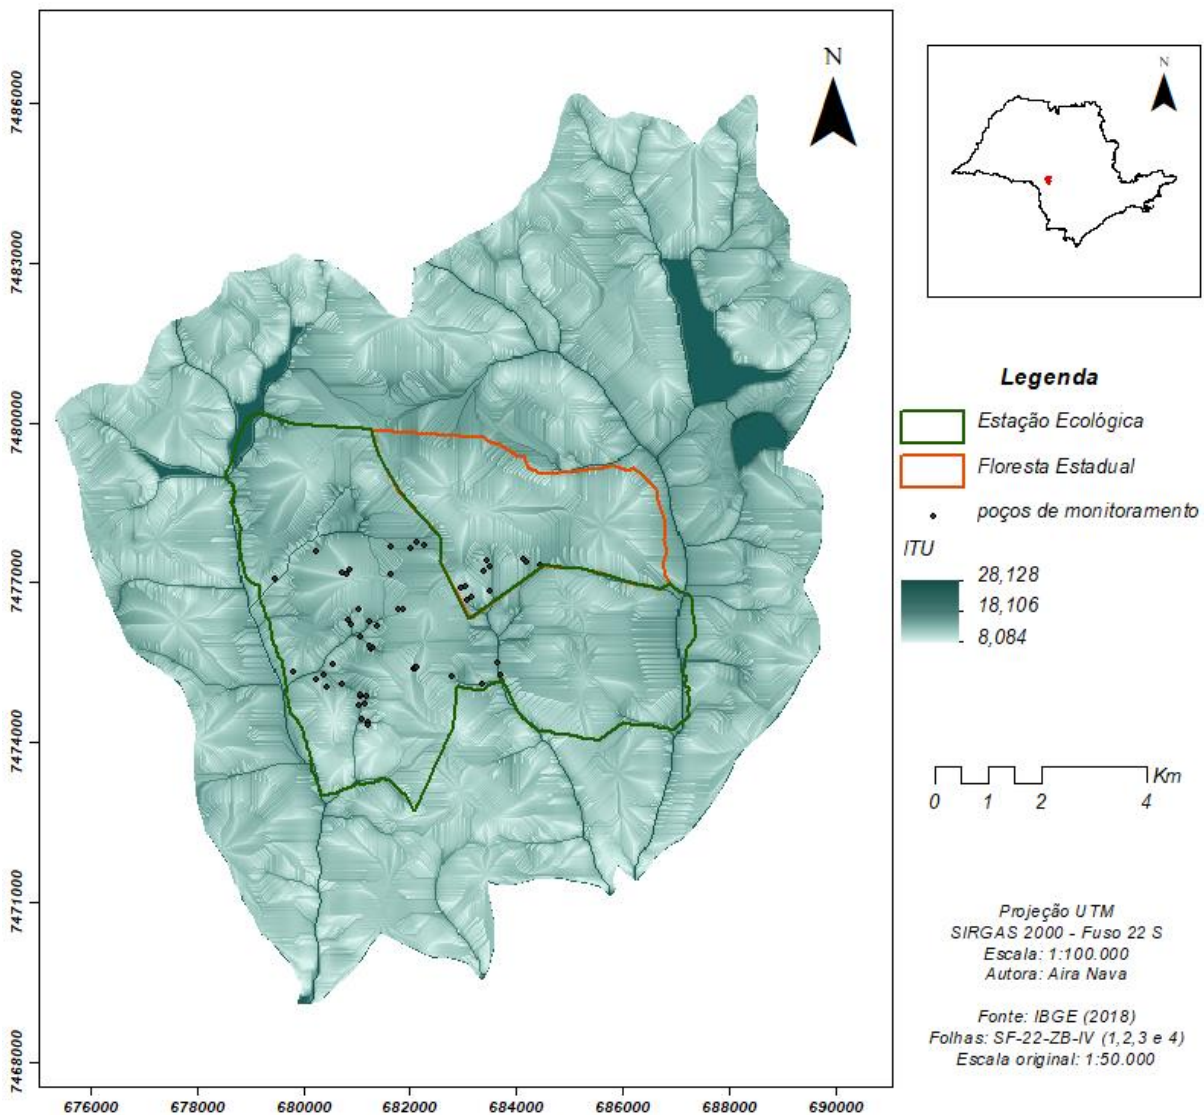


Em trabalhos realizados por Han et al. (2018) e Pöschke et al. (2018), as informações topográficas foram utilizadas para caracterizar o comportamento das águas subterrâneas. Boezio et al. (2006) utilizaram a topografia como informação secundária no procedimento de cokrigagem para o mapeamento do nível de água

subterrânea e concluíram que a utilização dessa variável preditora, na área de estudos, levou a modelos mais consistentes com o fenômeno natural.

Para representar a tendência de acúmulo de água no terreno, o ITU foi calculado com base nos mapas de MDE e declividade. Uma vez que o terreno não mostrou grandes variações na altimetria, o ITU nas áreas de estudo também apresentou pequena variação, com média de 14,42, mínima de 12,58 e máxima de 19,18. A Figura 23 mostra o ITU para as bacias nas quais as áreas de estudo se encontram, por meio da qual é possível observar que a tendência de acúmulo obedece ao relevo e os maiores valores se encontram próximos da rede de drenagem.

Figura 23 - Índice Topográfico de Umidade (ITU) para área de estudos



Apesar do ITU ser um dos índices mais utilizados para descrever as condições de umidade em escala de captação, Grabs et al. (2009) ressaltam que o índice tende a subestimar a extensão ou continuidade das áreas saturadas nos casos em que o relevo é plano. Apesar disso, Ågren et al. 2014 consideraram o ITU como um preditor útil de umidade do solo.

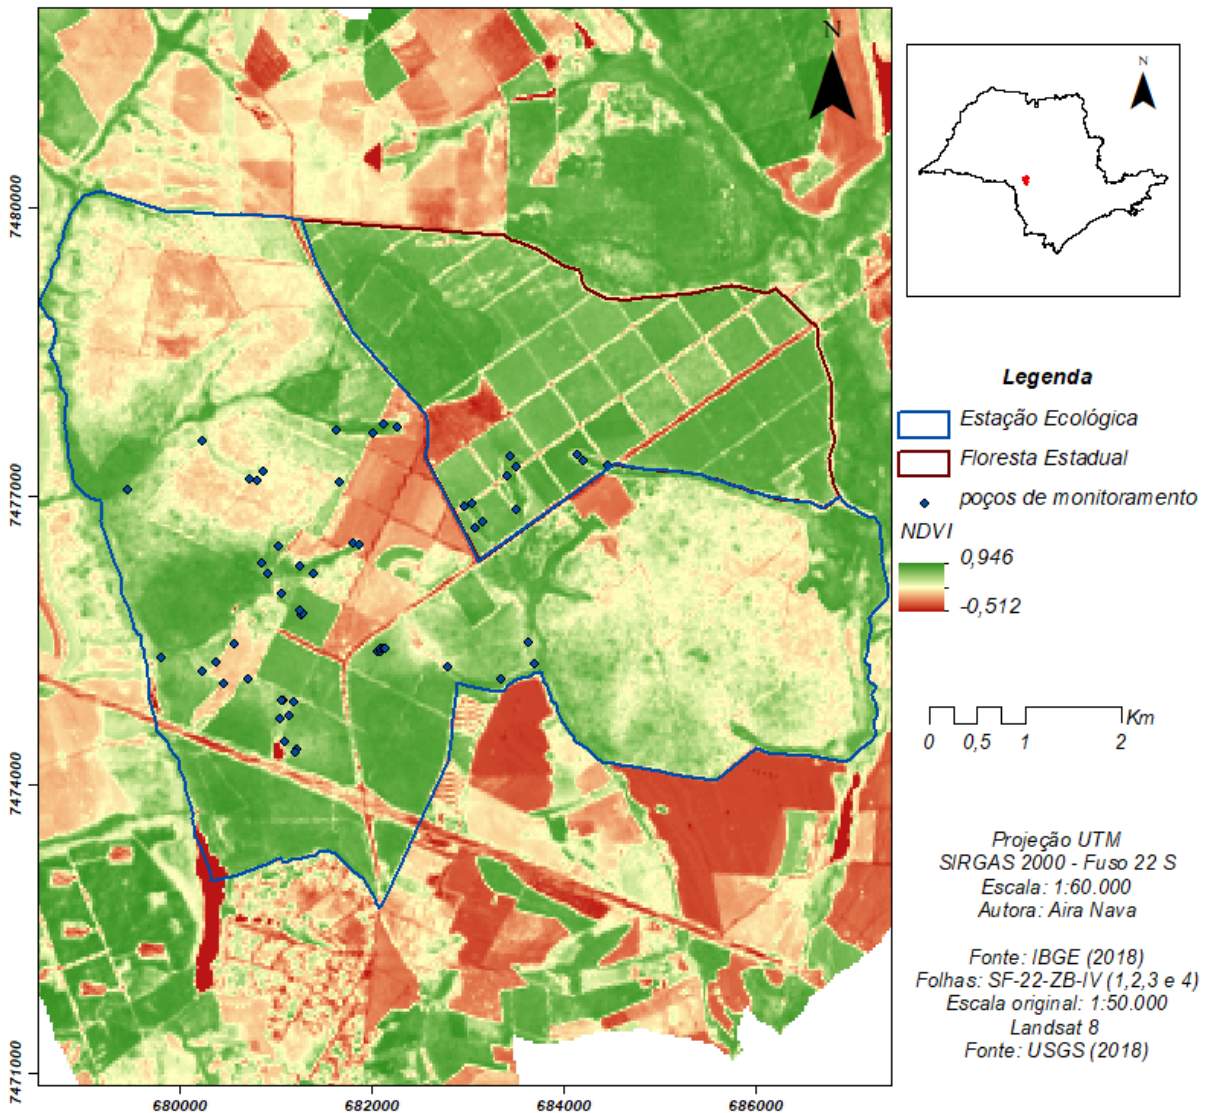
4.1.2. Variáveis da vegetação

Os índices de vegetação foram considerados no trabalho a fim de introduzir variáveis que estejam associadas as oscilações dos níveis de água subterrânea. Tais variáveis refletem a quantidade e vigor da biomassa e inserem um aspecto dinâmico no entendimento dos níveis freáticos da área, pois variam ao longo do tempo, condicionados pela sazonalidade e condições climáticas.

Para isso, foram selecionados tanto os índices que representam a vegetação do período (NDVI e EVI2) quanto os índices que consideram o a presença do solo para locais onde a cobertura vegetal é baixa (SAVI) e o teor de umidade na vegetação (NDWI). As Figuras 24 a 27 mostram os mapas com os valores para a área de estudo.

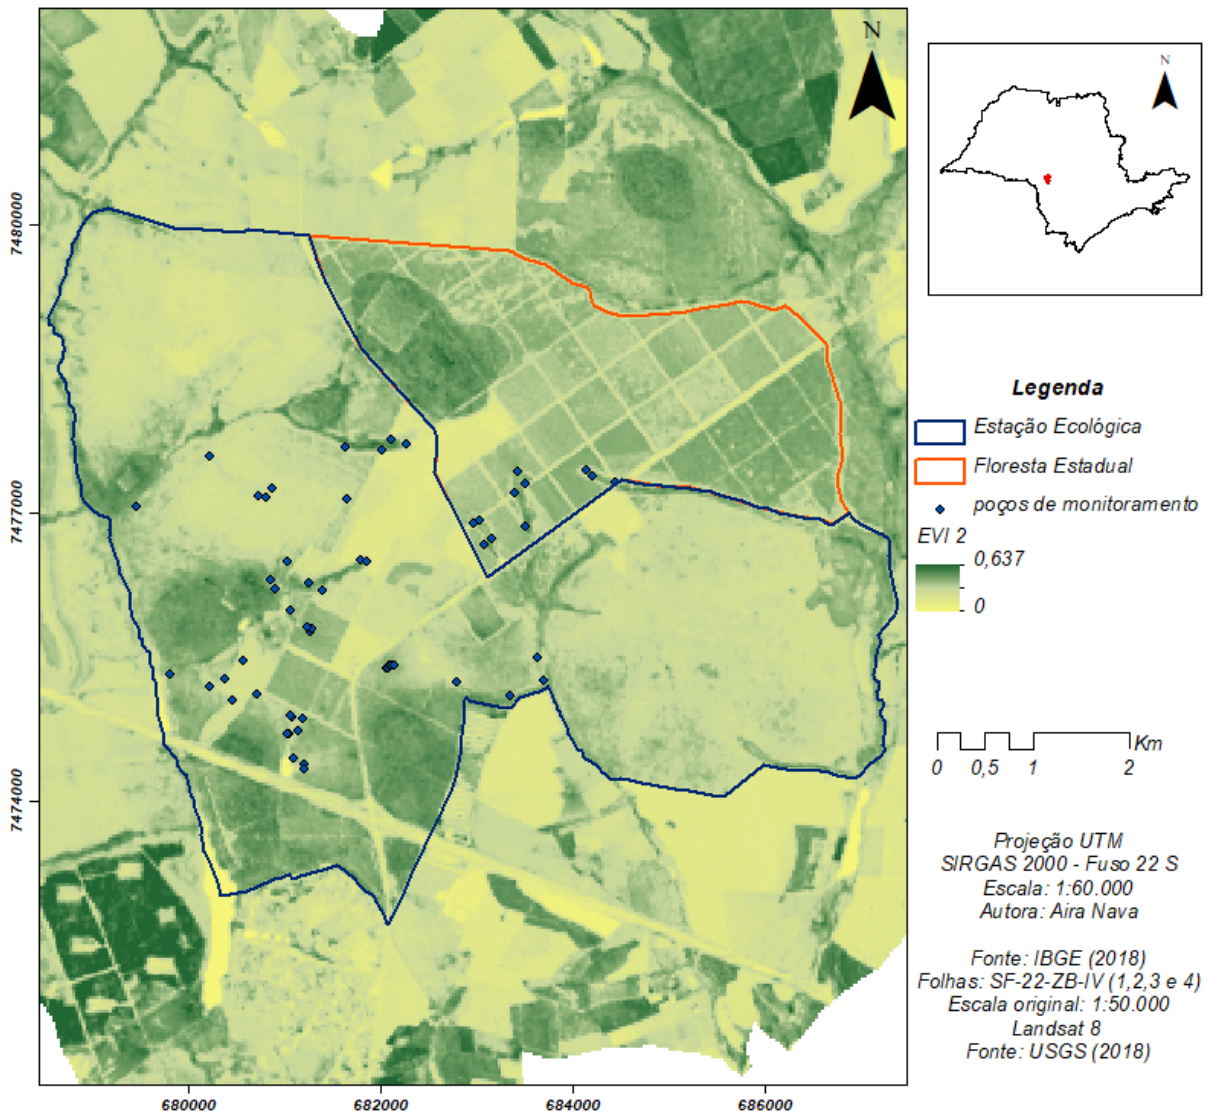
As Figuras 24 e 25 possibilitam compreender a configuração da área, por meio das quais é possível identificar os locais com diferentes densidades de vegetação, corpos hídricos, talhões, estradas e solo exposto. Por meio do NDVI, tem-se que, em geral, os poços de monitoramento se encontram em áreas com maior presença vegetação, o que é refletido nos níveis médios de 0,72 em torno dos poços. Os valores de NDVI variaram entre 0,47 e 0,87; e os valores de EVI2, entre 0,17 e 0,38.

Figura 24 - Índice de Vegetação por Diferença Normalizada (NDVI) para a área de estudo



Uma correlação positiva de 90% foi observada entre os índices NDVI e EVI2, o que indica coerência na obtenção dessas variáveis. Além disso, a PCA indicou um comportamento similar para ambas as variáveis sobre a variabilidade dos dados, indicando que, para a elaboração de um modelo, é possível utilizar apenas um desses índices.

Figura 25 - Índice de Vegetação Realçado (EVI 2) para área de estudo

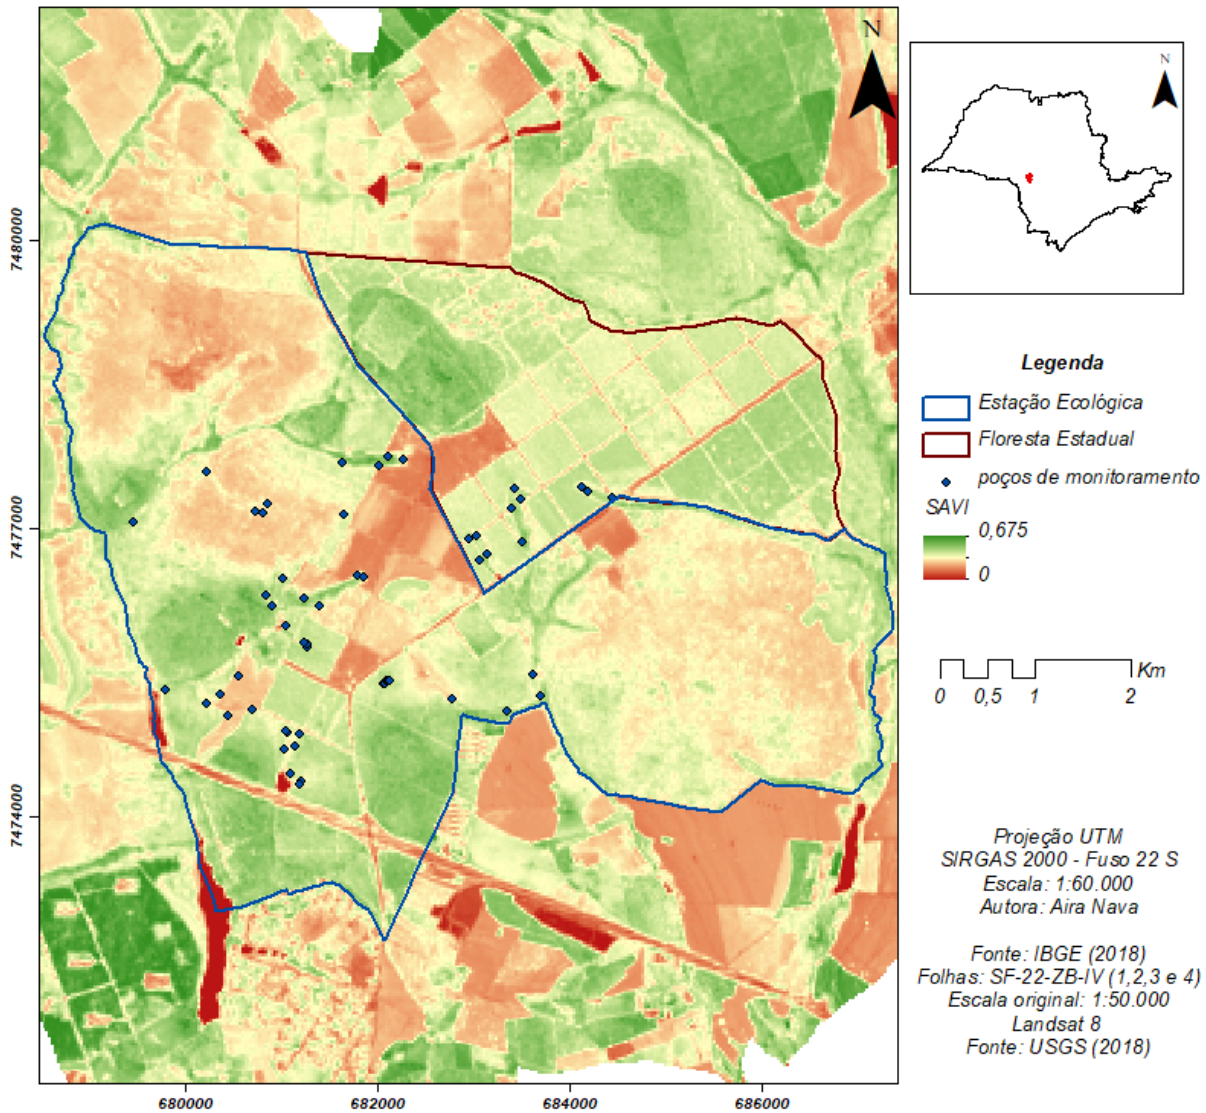


Manziona et al. (2014) analisaram as correlações existentes entre as respostas espectrais de culturas agrícolas e as oscilações dos níveis freáticos por meio de séries temporais obtidas de poços de monitoramento e do índice EVI2. Os autores concluíram ser possível, com base nos valores das séries de EVI2, explicar a interação entre a vegetação e os níveis freáticos em aquíferos livres e áreas de recarga direta.

Fu e Burgher (2015) estudaram a relação da dinâmica da vegetação ripária com o clima, a água superficial e a água subterrânea utilizando o NDVI. Entre os resultados, os autores encontraram que meses mais quentes necessitam de uma maior quantidade de chuva para manter os valores médios de NDVI quando comparados aos meses mais frescos, possivelmente devido a evapotranspiração.

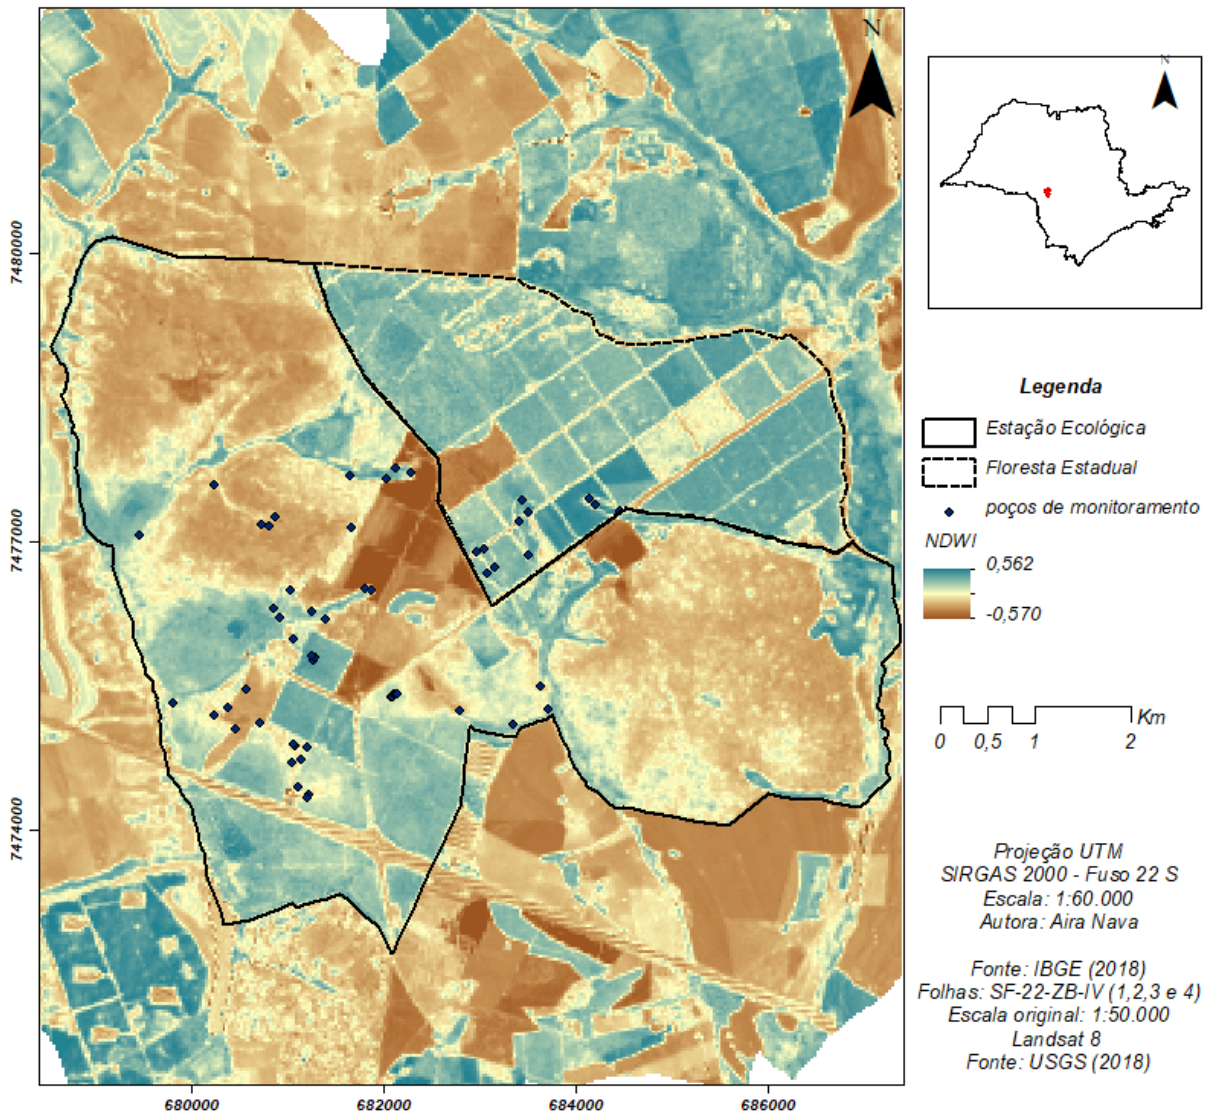
A fim de complementar as informações extraídas do NDVI e EVI2, as Figuras 26 e 27 mostram os resultados para o SAVI e NDWI.

Figura 26 - Índice de Vegetação Ajustado ao Solo (SAVI) para área de estudo



Os valores encontrados para o SAVI próximos aos poços de monitoramento variaram entre 0,24 e 0,42, com média de 0,35. O NDWI apresentou valor médio de 0,13, com valor máximo de 0,39 e mínimo de 0,15 ao redor dos poços.

Figura 27 - Índice de Umidade por Diferença Normalizada (NDWI) para área de estudo



Conforme destacado por Alaghamand et al. (2014), a vegetação pode influenciar significativamente na dinâmica do fluxo subterrâneo e afetar o balanço hídrico do solo por meio dos processos de crescimento, de transpiração e de interceptação. Dessa forma, o SAVI, ao realçar a presença do solo, pode complementar as informações onde a densidade da vegetação é menor, como em áreas de campo, vegetação esparsa ou solo exposto. E, o NDWI, representar a relação entre a umidade do solo e a presença de água nas folhas.

4.1.3 Variáveis relacionadas ao solo

Uma vez que as características físicas do solo influenciam no armazenamento e percolação da água no solo, buscou-se avaliar a relevância dessas informações por meio dos valores de areia, argila, silte (além das frações de areia), condutividade hidráulica (K) e resistência à penetração (RP) para as áreas entorno dos poços. Tais valores são apresentados resumidamente no item 4.2 (análise exploratória dos dados) e para cada poço no Apêndice A.

A importância em se considerar essas variáveis está relacionada ao favorecimento da infiltração pela presença de materiais porosos e permeáveis, como solos e sedimentos arenosos. Ressaltando que a diminuição da permeabilidade ocorre com o aumento da porosidade e diminuição do tamanho da partícula. Assim, as coberturas de solo são importantes no controle de infiltração por reter, temporariamente, parte da água que acaba sendo liberada lentamente para a rocha subjacente.

Com base nas análises granulométricas, Santarosa (2016) afirmou que a textura do solo é predominantemente arenosa, com porcentagem de areia entre 73% e 94% nas bacias estudadas. O fracionamento da areia mostrou a predominância de areia de granulometria média e fina. O valor médio de condutividade hidráulica entre os pontos de coleta, Figura 17, foi de $5.10^{-5} \text{ m s}^{-1}$.

Com base nas características do solo, os valores encontrados para RP caracterizaram uma baixa compactação dos solos (limite referente a uma compactação de até 2000 kPa em solos com teor de argila máximo de 20%) (EMBRAPA, 2011; FALKER, 2018). O valor médio de RP nas proximidades dos poços foi de 967 kPa.

De acordo com Oliveira et al. (1999), os Latossolos granulares presentes na região apresentam alta suscetibilidade à erosão e são pouco filtrantes, o que aumenta o risco de contaminação do aquífero livre por agrotóxicos e efluentes diversos. Tais solos são normalmente profundos, fortemente ácidos, com baixa saturação por bases, distróficos (pobres em nutrientes), ocasionalmente álicos (saturação por Al trocável superior a 50%), de textura média (concentrações de argila entre 15% e 35%) e com argila de atividade baixa (CTC inferior a 27 cmolc kg^{-1} argila).

Os Argissolos Vermelho-Amarelos são pobres em nutrientes (distróficos), contudo, a argila existente é de atividade alta (CTC maior ou igual a 27 cmolc kg⁻¹ argila). Os Nitossolos mostram capacidade para uso agrícola, com boa drenagem interna. Porém, estes solos apresentam como restrição a erodibilidade relativamente alta (OLIVEIRA et al, 1999).

4.2 Análise exploratória dos dados

A Tabela 1 mostra a média, mediana, valores máximos e mínimos, curtose, assimetria e desvio padrão de cada variável. Os valores das variáveis para cada poço de monitoramento podem ser encontrados nos Apêndices B e C.

Tabela 1 - Estatística descritiva das variáveis explicativas

	Variável	Média	Mediana	Máximo	Mínimo	Curtose	Assimetria	D. Pad.
Terreno	Distância	142,05	57,26	690,54	2,11	2,41	1,24	204,91
	Elevação	645,57	640,36	659,23	634,96	-1,45	1,93	8,1
	Declividade	1,39	0,99	4,94	0,21	2,03	1,09	1,1
	ITU	14,42	13,95	12,59	19,18	3,3	0,94	1,51
Índices de vegetação	NDVI	0,72	0,73	0,87	0,47	0,22	-0,39	0,09
	SAVI	0,35	0,36	0,44	0,24	0,44	-0,39	0,04
	EVI2	0,28	0,28	0,39	0,17	0,1	-0,23	0,04
	NDWI	0,13	0,14	0,4	-0,15	-0,54	-0,18	0,14
Características do solo	Areia	84,94	84,89	92,8	75,48	-0,77	0,03	4,21
	Argila	13,62	13,45	22,6	5	-0,87	0,12	4,23
	Silte	1,44	1,44	2,8	0,26	-1,2	-0,01	0,7
	Muito fina	13,17	13,03	20,87	8,18	0,05	0,15	2,79
	Fina	48,01	47,93	55,47	37,46	0,46	0,07	3,74
	Média	35,75	35,75	44,14	25,05	-0,43	0	4,88
	Grossa	3,04	2,73	8,01	1,17	4,23	0,64	1,43
	K (m/dia)	6,68	4,87	19,31	3,6	3,72	1,19	4,55
	RP (kPa)	967,31	917,49	1890	450	0,49	0,45	332,18
Águas subterrâneas	Nível médio	-1,02	-0,8	-0,02	-5,2	4,98	-0,61	1,06
	Nível máximo	-0,57	-0,27	0	-3,44	3,41	-1,1	0,81
	Nível mínimo	-1,65	-1,35	0,15	-7,35	4,37	-0,63	1,41
	Temperatura	20,01	20	22,5	18	-0,17	0,03	1,05
	Estimados*	-1,03053	-0,6708	0,1701	-4,879	4,393458	-1,97	1,09
Resíduos*	-0,00799	0,0009	0,589	-0,4091	1,001371	0,38	0,18	

Unidades: metros para elevação, distância, níveis médio, máximo e mínimo; porcentagem: declividade, areia, argila, silte e frações da areia; condutividade hidráulica (K) em md^{-1} ; resistência a penetração (RP) em KPa; temperatura em °C. * Valores obtidos com o ajuste do modelo determinístico.

Além das variáveis citadas anteriormente, temperatura da água nos poços e a distância euclidiana entre os poços de observação e a rede de drenagem mais próxima também foram consideradas. A interação com as águas superficiais interfere nos fluxos e trocas com as AS (WINTER et al., 1998). Xi et al. (2010) descobriram que o fluxo do rio poderia influenciar significativamente as flutuações dos níveis freáticos nas águas perto das margens do rio.

A temperatura da água está relacionada ao coeficiente de permeabilidade (quanto maior a temperatura, menor a viscosidade da água e, portanto, maior o escoamento pelos vazios do solo com correspondente aumento do coeficiente de permeabilidade) (KARMANN, 2003).

O desvio padrão, que representa o quão dispersos os dados estão da média, mostrou dados consistentes, como exemplo, no caso da variação de 0,09 para o NDVI; 0,4 para o EVI2; 8,10 metros para a elevação e 1,06 cm para o nível freático médio.

4.3 Análise de componentes principais

Uma vez que as 21 variáveis ambientais foram obtidas, seus valores encontrados foram extraídos para cada um dos 56 pontos de medição do nível freático. A variabilidade dos dados foi explicada pela análise de componentes principais. Os resultados mostraram que a variabilidade mínima global foi alcançada com as cinco primeiras componentes, com variância acumulada de 70%, conforme exposto na Tabela 2.

Tabela 2 – Autovetores calculados para as primeiras cinco componentes principais (PC) obtidas a partir da PCA

	Variável	PC1	PC2	PC3	PC4	PC5
Terreno	Distância	0,13	-0,27	0,36	-0,05	0,07
	Elevação	0,18	-0,06	0,35	-0,11	-0,07
	Declividade	0,10	0,22	0,27	0,10	0,12
	ITU	-0,01	-0,10	-0,32	0,07	-0,19
Índices de vegetação	NDVI	0,29	-0,14	-0,05	0,32	-0,06
	SAVI	0,26	-0,19	-0,10	0,34	-0,05
	EVI2	0,28	-0,18	-0,11	0,34	-0,06
	NDWI	0,28	-0,12	-0,13	0,29	-0,21
Características do solo	Areia	0,18	-0,17	0,22	-0,24	-0,41
	Argila	-0,15	0,18	-0,18	0,30	0,41
	Silte	-0,13	-0,02	-0,23	-0,32	-0,05
	Muito fina	-0,23	0,18	0,08	0,25	-0,22
	Fina	-0,21	0,16	0,27	0,26	-0,22
	Média	0,25	-0,20	-0,16	-0,28	0,26
	Grossa	0,15	-0,08	-0,34	-0,22	0,10
	K	0,18	-0,14	0,34	-0,10	0,17
	RP	-0,02	0,01	-0,20	-0,12	-0,44
Águas subterrâneas	Nível médio	0,27	0,36	-0,04	-0,09	-0,09
	Nível máximo	0,28	0,31	0,03	-0,11	-0,13
	Nível mínimo	0,23	0,38	-0,09	-0,05	0,04
	Temperatura	-0,17	-0,35	-0,07	0,04	0,06
	Cumulativo	0,24	0,41	0,53	0,63	0,70

Unidades: metros para elevação, distância, níveis médio, máximo e mínimo; porcentagem: declividade, areia, argila, silte e frações da areia; condutividade hidráulica (K) em md^{-1} ; resistência a penetração (RP) em KPa; temperatura em °C. * Valores obtidos com o ajuste do modelo determinístico.

A partir das cinco componentes principais, foi possível selecionar as variáveis originais de maior representatividade para elaboração do modelo de predição espacial. Para definir as aquelas que melhor representaram a variabilidade dos dados, foram considerados os valores dos coeficientes das funções PCA acima de 0,34 em módulo. Assim, as variáveis SAVI, EVI2, areia, argila, níveis médios e mínimos, resistência à penetração e temperatura foram selecionadas.

4.4 Ajuste do modelo determinístico para estimativa do nível médio do lençol freático

Com base nos resultados obtidos na PCA, avaliou-se a significância das oito variáveis ambientais selecionadas. A Tabela 3 mostra variáveis que foram significativas e que foram utilizadas no modelo de regressão linear múltiplo.

Tabela 3 – Valores de significância das variáveis preditoras

Variável ambiental	valor <i>p</i>
SAVI	0,010
EVI	0,018
Areia	0,002
Argila	0,002
Nível médio	<0,000

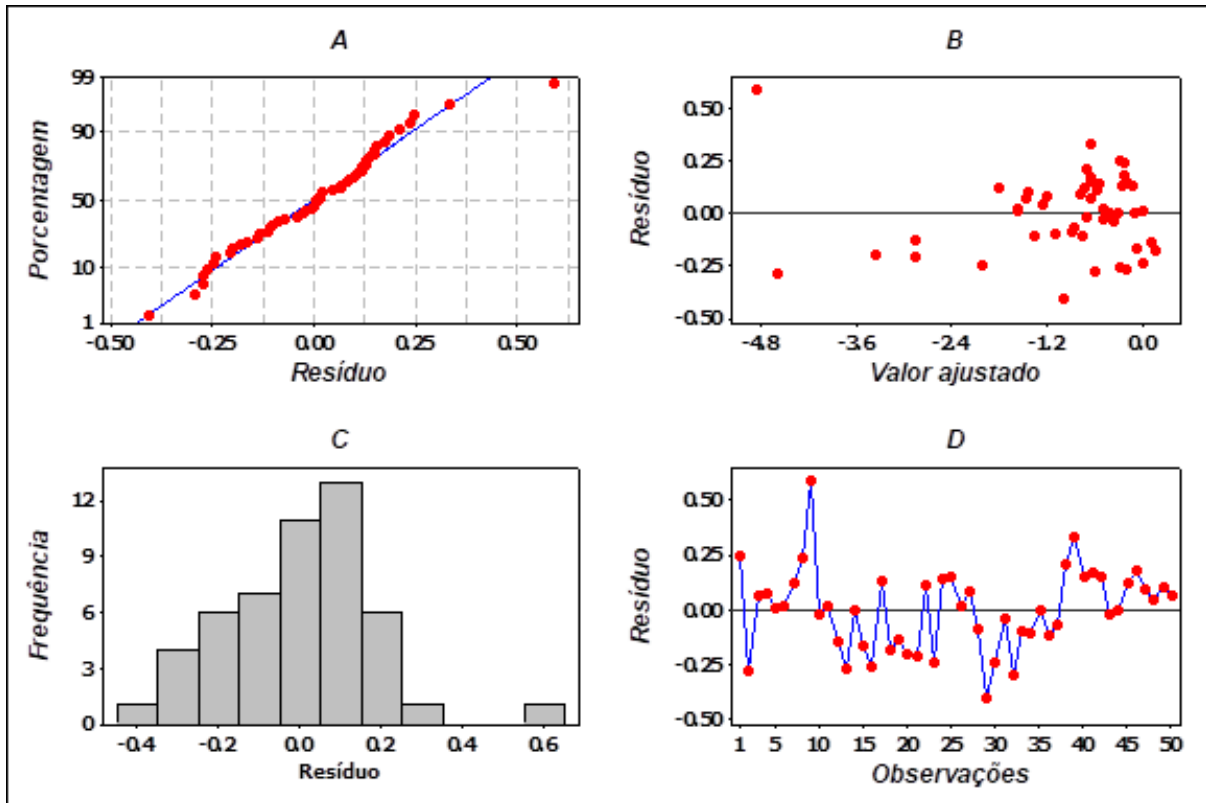
O modelo encontrado é dado na Equação 20, conforme mencionado por SASSI et al. (2012) na Equação 8.

$$N = -15,8229 + 12,3639 \text{ SAVI} - 10,1618 \text{ EVI2} + 0,146338 \text{ Areia} + 0,139064 \text{ Argila} + 0,981268 \text{ NM} \quad (20)$$

Onde SAVI e EVI2 correspondem aos índices de vegetação; areia e argila ao fracionamento do solo e NM ao nível médio do lençol freático.

Os resultados mostraram que, para a data proposta de 10 de setembro de 2017, o modelo apresenta um ajuste robusto aos dados. A porcentagem que é explicada pelo modelo corresponde a 97%, no entanto, o R² predito foi de 95%, mostrando que o modelo tem capacidade preditiva para novas observações. A avaliação do modelo pode ser observada na Figura 28 e o ajuste na Figura 29.

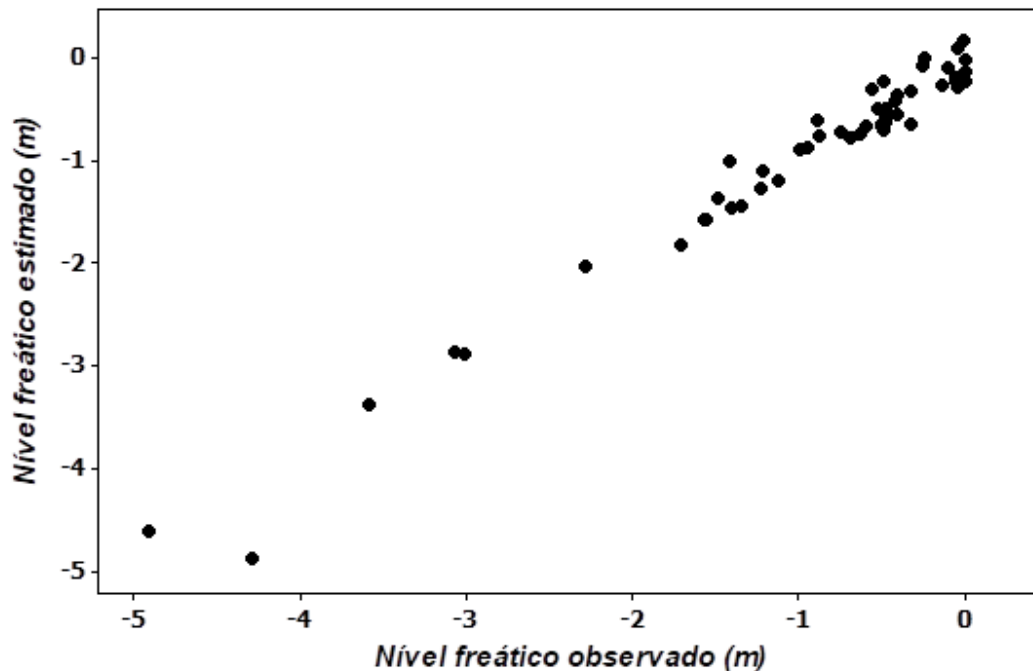
Figura 28 – Avaliação do modelo de predição dos níveis freáticos



O comportamento linear do modelo é observado nos gráficos da Figura 28A e 28B, com os pontos próximos da linha de regressão ajustada e com os resíduos dos valores ajustados entre 0,25 e -0,25. Os resíduos das observações representam o desvio padrão de 0,19 metros indicado nas estatísticas de ajuste.

A Figura 29 mostra uma comparação entre os dados observados e os dados estimados pelo modelo. Percebe-se que os valores estimados pelo modelo são bastante próximos aos dados observados em campo. Isso demonstra a funcionalidade e o ajuste robusto do modelo.

Figura 29 – Comparação entre os dados observados e os dados estimados pelo modelo



O nível médio representa a série histórica de oscilação. A areia e a argila correspondem a fatores estáticos e estão relacionadas com o armazenamento e infiltração. Por fim, os índices de vegetação representam a sazonalidade e a sensibilidade frente as variações climáticas.

Em conformidade com os resultados encontrados, Manzione et al. (2015) utilizaram análise fatorial multivariada para identificar os principais fatores que influenciam nas variações do lençol freático em uma área de afloramento do Sistema Aquífero Guarani, em Brotas/SP. As variáveis de maior relevância foram: tamanho das partículas de areia, atributos do terreno, vegetação e manejo do solo; sendo que o tamanho das partículas e os atributos do terreno foram considerados as principais forças responsáveis pela flutuação da água subterrânea na bacia.

Yan et al. (2018) utilizaram um modelo de regressão linear para estimar o lençol freático diário em uma planície costeira. Com um coeficiente de determinação de 84%, encontraram que o nível responde as variáveis climáticas de temperatura e de evapotranspiração e ao estágio do rio localizado a 2 km das medições.

Salles et al. (2018), por meio do método dos quadrados mínimos, identificaram ser possível estimar a quantidade de água armazenada em aquíferos porosos e o

comportamento da água subterrânea em solos do planalto central brasileiro a partir da geomorfologia e das características físicas do solo.

4.5 Modelagem da estrutura de variabilidade espacial

Os valores estimados pela regressão linear múltipla (RLM) e os resíduos do modelo determinístico foram submetidos à análise de dependência espacial (Tabela 4), na qual foi possível ajustar o semivariograma teórico ao semivariograma experimental. Para a modelagem, buscou-se observar o comportamento dos pontos no início do gráfico e o número de pares utilizados para encontrar o valor da variância.

Tabela 4 - Modelos e parâmetros dos semivariogramas isotrópicos ajustados aos níveis médios do lençol freático e aos resíduos estimados na regressão linear múltipla.

Variável	Modelo	Efeito Pepita (C_0)	Patamar (C)	Alcance (a)	Nº de lags
Nível Estimado	<i>Stable</i>	0,040	1,385	937,83	12
Resíduos	Gaussiano	0,000	0,050	800,74	10

Os resultados mostraram que o efeito pepita encontrado nos modelos foi baixo. O efeito pepita representa a variabilidade para intervalos menores que a distância de amostragem e é causado por erros de amostragem e erros de medidas da variável analisada. Dessa forma, há descontinuidade na origem do semivariograma, indicando uma variabilidade não explicada de um ponto para outro (MACHADO et al., 2007; ALESSI, 2011).

O alcance mostrou que a dependência espacial dos níveis estimados foi de 937,83 metros e dos resíduos foi de 884,55 metros. Tais amplitudes semivariográficas mostram a distância a partir da qual a variação média entre duas observações não é mais função da distância entre elas, tornando-as independentes. O alcance reflete, também, a homogeneização entre as amostras, ou seja, quanto maior for o seu valor, mais homogêneo será o fenômeno ou processo estudado (ALESSI, 2011).

Os patamares mostraram que o semivariograma dos níveis estimados se estabilizou em 1,385 metros e dos resíduos em 0,034 metros. O patamar é atingido quando a variância dos dados se torna constante com a distância entre as amostras e deve se aproximar da variância total dos dados.

As Figuras 30 e 31 mostram os semivariogramas ajustados aos níveis freáticos médios estimados e aos resíduos da RLM.

Figura 30 – Semivariograma isotrópico para a estimativa dos níveis freáticos médios





Figura 31 – Semivariograma isotrópico para a estimativa dos resíduos da RLM



A Tabela 5 mostra as estatísticas da validação para os semivariogramas ajustados. Para a avaliação dos modelos foram considerados os valores do erro médio (ME), da raiz do erro médio quadrático padronizado (RMSS), média do erro padronizado (MEP) e as menores raízes do erro médio quadrático (RMSE) encontradas durante a modelagem.

Tabela 5 - Estatísticas da validação para os semivariogramas ajustados.

Variável	ME	RMSS	MEP	RMSE
Nível Estimado	0,01	1,27	0,01	1,07
Resíduos	-0,006	1,21	-0,01	0,67

Conforme Johnston et al. (2001), os erros médios devem ser próximos de zero, as raízes dos erros médios quadráticos padronizados devem ser próximas de 1 e as médias dos erros padronizado, próximas de 0. O RMSS quando está abaixo de 1 mostra que os valores interpolados foram subestimados e quando está acima de 1, mostra que foram superestimados.

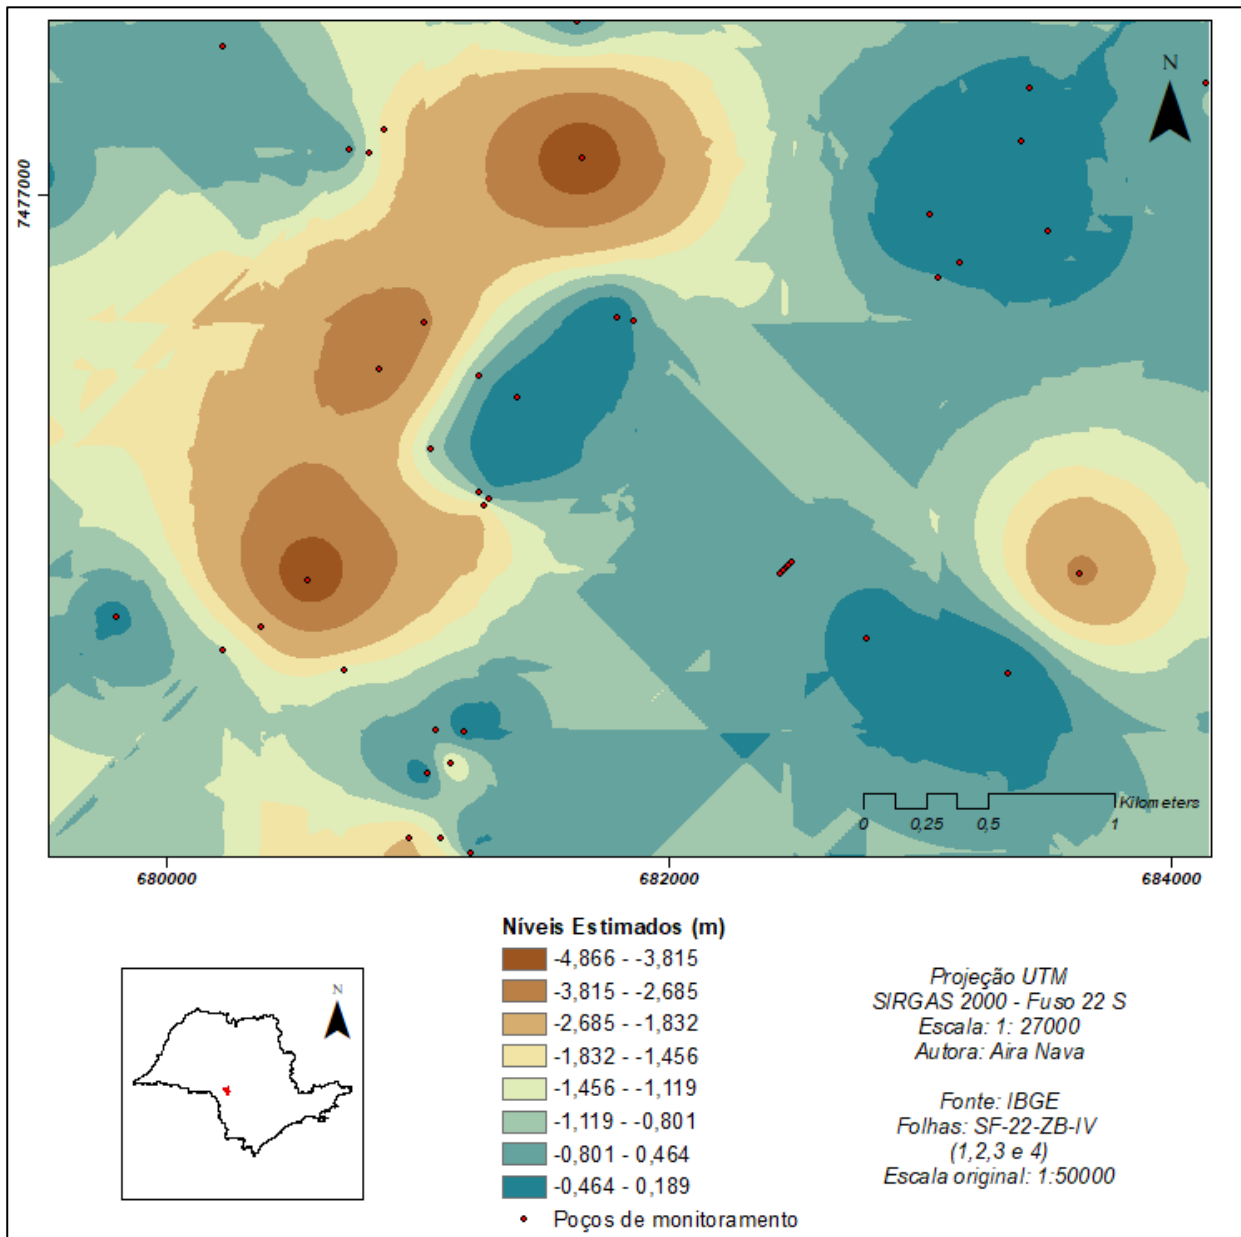
Os valores obtidos para os semivariogramas ajustados se encontram próximos dos valores de referência. Os valores do RMSS também estão relacionados ao efeito de suavização da interpolação por KO que desconsidera os valores extremos da distribuição dos dados durante o processo (YAMAMOTO; LAMDIM, 2013).

4.6 Mapeamento da água subterrânea

Após o ajuste dos semivariogramas, os dados foram interpolados por meio da krigagem ordinária. As Figuras 32 e 33 mostram os mapas obtidos para os níveis médios estimados do lençol freático e para os resíduos do modelo.

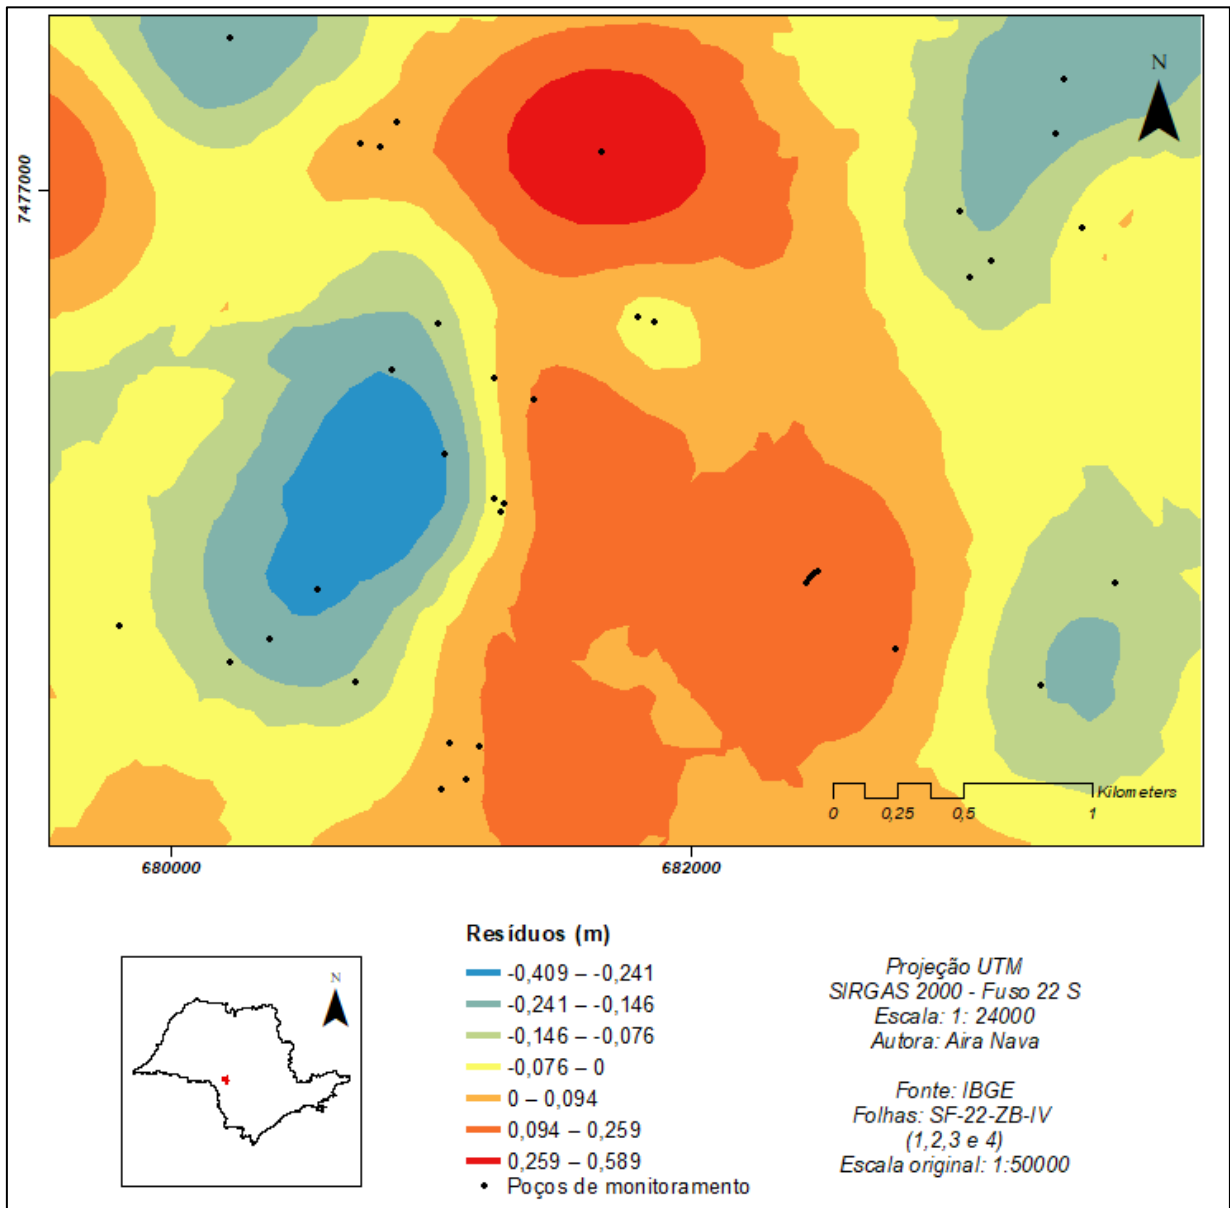
No mapa da Figura 32, observa-se descontinuidades nos valores encontrados. A dificuldade de interpolação dos dados pode ser explicada pela quantidade de pontos amostrais utilizados na análise e por sua distribuição irregular nas bacias monitoradas.

Figura 32 – Mapa de interpolação por krigagem ordinária dos níveis freáticos médios



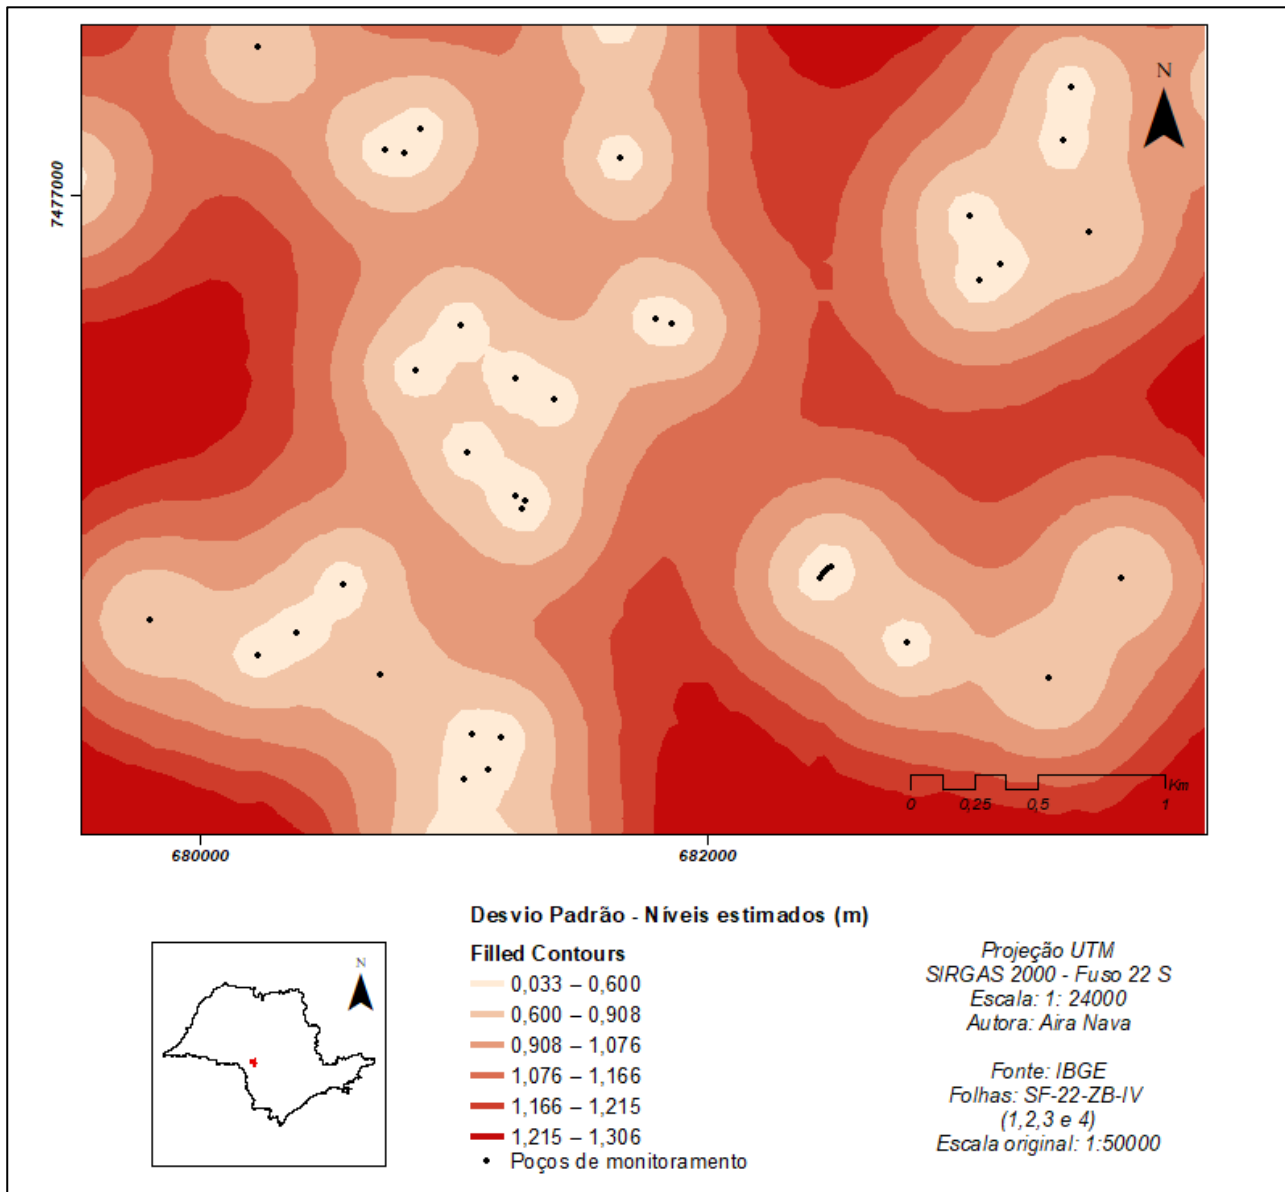
O mapa de interpolação da Figura 33 mostra que os resíduos variaram com maior frequência entre -0,08 e 0,09 metros. Esses valores estão relacionados com as diferenças entre os valores coletados em campo e os estimados pela RLM. Com base na concentração dos dados, tem-se que os valores estimados variaram pouco dos valores medidos nos poços de monitoramento.

Figura 33 – Mapa de interpolação por krigagem ordinária dos resíduos dos níveis freáticos médios



As Figuras 34 e 35 mostram as incertezas encontradas no processo de interpolação dos dados. Os mapas de desvio-padrão (DP) auxiliam na verificação da eficiência do modelo adotado, pois indicam a dispersão dos dados da amostra com relação à média.


Figura 34 – Mapa de interpolação por krigagem ordinária do desvio-padrão níveis freáticos médios estimados



Observa-se que os valores dos desvios-padrão aumentam a partir dos pontos amostrais. Na figura 34, tem-se que nas proximidades dos poços de monitoramento, os valores encontrados variam em até 60 cm. No entanto, conforme ocorre o distanciamento dos pontos amostrais, os valores DP aumentam e podem chegar a 1,3 metros.

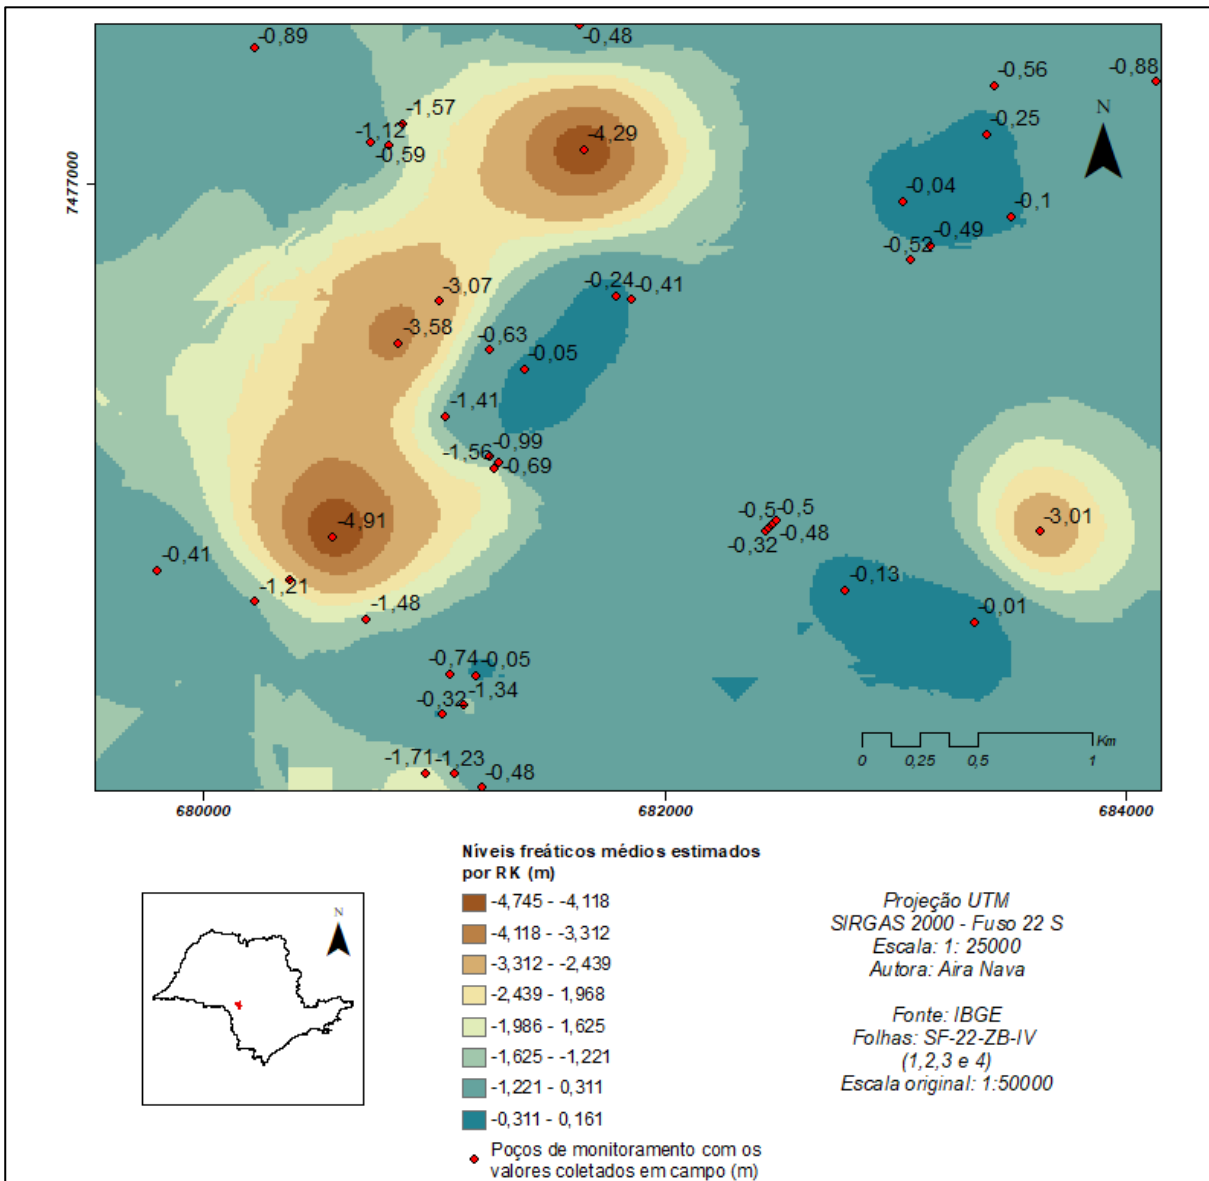
A Figura 35 mostra as mesmas características do mapa anterior, no qual as certezas diminuem conforme ocorre o distanciamento dos pontos de monitoramento. Porém, os valores encontrados apresentam uma amplitude menor, variando em 17 cm ao longo de toda a área.

Figura 35 – Mapa de interpolação por krigagem ordinária do desvio-padrão resíduos dos níveis freáticos médios



A Figura 36 mostra o mapa final predito para os níveis médios de lençol freático. Para sua elaboração, o mapa dos resíduos foi adicionado ao mapa predito com a finalidade de melhorar sua qualidade. A fim de auxiliar na interpretação dos resultados obtidos no processo de regressão-krigagem, os valores coletados em campo foram acrescentados ao mapa.

Figura 36 – Mapa final dos níveis freáticos médios elaborado por meio do modelo de regressão-krigagem



Pela Figura 36, nota-se que os valores coletados em campo são coerentes com os valores dos intervalos. Os níveis médios mais profundos se encontram na porção oeste da área, região que pertence à bacia do Santana e à bacia do Guarantã. Esses níveis mais profundos acompanham os divisores de água das bacias, o que indica a influência do relevo na posição média do lençol e no escoamento da água. Essa característica também pode ser observada na bacia do Bugre. Nesse sentido, as áreas com menores declividades apresentaram os níveis mais superficiais.

Manzione (2018) mapeou as tendências de elevação e o tempo de reposta das águas subterrâneas aos eventos de precipitação. Os estudos mostraram que o tempo

de resposta é menor nas áreas próximas da drenagem, onde a espessura da camada não saturada é menor que as encontradas próximas aos divisores de água. As maiores elevações foram localizadas nas bacias do Guarantã e do Santana, que confluem para o Rio Capivari e forma uma série de áreas úmidas e alagadas.

A distribuição dos níveis de água subterrânea encontrada por meio da regressão-krigagem é coerente com os estudos de Santarosa e Manzione (2017), que mapeou o lençol freático com auxílio da cokrigagem dos atributos dos solos coletados na área e de dados topográficos. Os resultados mostraram que a adoção das variáveis auxiliares foi capaz de melhorar as estimativas espaciais, reduzindo a variância amostral e suavizando os erros nas previsões.

A regressão-krigagem pode aplicada em localizações com cenários diferentes que influenciam nas oscilações dos níveis freáticos. Sua abrangência depende dos objetivos do pesquisador e sua viabilidade depende das variáveis explicativas disponíveis para o local de interesse.

Para Healy (2010), as técnicas de regressão são comumente empregadas em estudos hidrológicos por múltiplos propósitos. Essas técnicas podem ser aplicadas em qualquer lugar onde os valores dos parâmetros são conhecidos ou desejam ser estimados.

A flexibilidade para a utilização das técnicas de regressão nas pesquisas de águas subterrâneas pode ser exemplificada em trabalhos como o de Yan et al. (2018), que estimou o lençol freático em planície costeira chinesa localizada em zona subtropical. Salles et al. (2018) encontrou as variáveis relacionadas a variação das águas subterrâneas de uma área majoritariamente rural no cerrado de clima tropical.

Métodos geoestatísticos são frequentemente empregados para mapear a superfície livre de um aquífero. Theodoridou et al. (2017), por exemplo, utilizaram o método de mínimos quadrados, o critério de informação de Akaike e o indicador de Cressie para avaliar os variogramas e espacializar as águas subterrâneas por krigagem ordinária. E, para definir os vizinhos apropriados em cada ponto de estimativa, utilizaram algoritmos da Lógica *Fuzzy*.

Com base nos resultados encontrados para a data estudada, a ferramenta RK se mostrou promissora para o planejamento da área, pois os valores encontrados se aproximaram dos coletados em campo. A combinação das componentes determinística com a componente estocástica possibilitou entender a distribuição das águas subterrâneas.

5 CONCLUSÕES

1. A krigagem ordinária dos resíduos gerados pelo modelo de regressão linear múltipla foi capaz de aprimorar o mapa com os dados estimados e proporcionar um refinamento ao mapa final de predição dos níveis freáticos da área, garantindo maior precisão aos resultados que poderão servir como instrumentos de gestão dos recursos hídricos.
2. Foi possível, com as variáveis utilizadas no estudo, obter um modelo determinístico que explicou a variação dos níveis freáticos da área de estudo.
3. Pela análise de componentes principais foi possível explicar a variabilidade global dos dados e selecionar as variáveis de maior importância, reduzindo o conjunto inicial dos dados.
4. O conjunto das variáveis utilizadas mostrou a importância das propriedades físicas do solo e da presença da vegetação sobre os níveis de água subterrânea.
5. mostraram que o modelo apresenta ajuste robusto aos dados e capacidade preditiva a novas observações, com R^2 de 97% e R^2 ajustado de 95%.
6. Por meio da modelagem dos semivariogramas, foi possível estabelecer a autocorrelação espacial dos níveis médios e dos resíduos encontrados na RLM.
7. O ajuste dos semivariogramas possibilitou a krigagem ordinária dos níveis freáticos médios e dos resíduos do modelo determinístico. Entretanto, os resultados da espacialização foram influenciados pelos poucos pontos amostrais e pelo agrupamento desses pontos em uma malha irregular.

6 CONSIDERAÇÕES FINAIS

Espera-se, com isso, que o ajuste do modelo seja útil para pesquisas futuras e que facilite a obtenção de informações sobre as águas subterrâneas para o monitoramento desse recurso.

A modelagem com base em diferentes variáveis, como precipitação e evapotranspiração, pode acrescentar informações importantes aos resultados encontrados e ajudar no entendimento dos processos que influenciam nas oscilações dos níveis freáticos.

A obtenção de series temporais de águas subterrâneas ainda é um desafio, por isso, a elaboração de modelos capazes de estimar os níveis freáticos são essenciais para a elaboração de planos de manejo e para que o uso dessas águas seja feito de modo sustentável.

REFERÊNCIAS

- ALAGHMAND, S. et al. Impacts of Vegetation Cover on Surface-Groundwater Flows and Solute Interactions in a Semi-Arid Saline Floodplain: A Case Study of the Lower Murray River, Australia. **Environmental Processes**, v. 1, n. 1, p. 59 – 71, 2014.
- ALESSI, C. C. **Análise Estatística e Geoestatística da Distribuição de CO₂, CH₄, Rn e Microbiota em um Campo Petrolífero do Recôncavo Baiano (BA)**. 218 f. 2011. Dissertação (Mestrado em Engenharia Civil) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2011.
- ANDRIOTTI, J. L. S. Análise de componentes principais: fundamentos de uma técnica multivariada aplicada a dados geológicos. **Acta Geológica Leopoldensia**. v. 20, n. 44, p. 21 – 50, 1997.
- ANDRIOTTI, J. L. S. **Fundamentos de estatística e geoestatística**. São Leopoldo: Editora UNISINOS, 2003. 165p.
- BALLERINE, C. **Topographic Wetness Index: Urban Flooding Awareness Act** Action Support. Disponível em: <https://www.isws.illinois.edu/pubdoc/CR/ISWSCR2017-02.pdf>. Acesso em: jun. de 2018.
- BERNARDI, J. V. E. Aplicação da análise das componentes principais na ordenação dos parâmetros físicos-químicos no alto Rio Madeira e afluentes, Amazônia Ocidental. **Geochimica Brasiliensis**, v. 23, p. 79 – 90, 2009.
- BEVEN, K. J.; KIRKBY, M. J. A. Physically based variable contributing area model of basin hydrology. **Hydrological Sciences Bulletin**, Wallingford, v. 24, p. 43-69, 1979.
- BOEZIO, N. M. N. et al. Cokrigagem colocada aplicada ao mapeamento do nível de água subterrânea. **Revista Escola de Minas**, v. 59, n. 2, p. 159 – 164, 2006.
- BUSSAB, W. O.; MORETTIN, P. A. **Estatística Básica**. 6ª edição. São Paulo. Editora Saraiva, 2010. 534 p.
- BUTLER, J. J. et al. A field investigation of phreatophyte-induced fluctuations in the water table. **Water Resources Research**, v. 43, p. 289 – 316, 2007.
- CAMPOS, S. et al. Sensoriamento remoto e geoprocessamento aplicados ao uso da terra em microbacias hidrográficas, Botucatu – SP. **Engenharia Agrícola**, v.24, n.2, p.431-435, 2004.
- CARVALHO, T. M. **Modelagem digital de atributos de solo da Fazenda Edgárdia – Botucatu – SP**. 145 f. 2016. Tese (Doutorado em Agronomia) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2016.

CATEN, A. T. **Aplicação de Componentes Principais e Regressões Logísticas Múltiplas Em Sistema de Informações Geográficas para a Predição e o Mapeamento Digital de Solos**. 104 f. 2008. Dissertação (Mestrado) - Universidade Federal de Santa Maria (UFSM), Santa Maria, 2008.

CEPAGRI - CENTRO DE PESQUISAS METEOROLÓGICAS E CLIMÁTICAS APLICADAS À AGRICULTURA. **Clima dos municípios de São Paulo**. Disponível em: <http://www.cpa.unicamp.br/outras-informacoes/clima-dos-municipios-paulistas.html>. Acesso em: dez/2015

CERAR, S.; MALI, N. Assessment of presence, origin and seasonal variations of persistent organic pollutants in groundwater by means of passive sampling and multivariate statistical analysis. **Journal of Geochemical Exploration**, v. 170, p. 78 – 93, 2016.

CHRISTOFOLETTI, A. **Modelagem de Sistemas Ambientais**. São Paulo, SP: Edgard Blücher, 1999. 236 p.

CONGEDO, F. **Semi-Automatic Classification Plugin Documentation**. Disponível em: <https://fromqistors.blogspot.com/p/semi-automatic-classification-plugin.html>. Acesso em: mai. de 2018.

COLERIDGE, S. T. O ciclo da água e a água subterrânea. In: PRESS, F. et al. **Para entender a Terra**. 4 ed. Porto Alegre: Bookman, 2006. 656p.

CONDON, L. E.; MAXWELL, R. M. Evaluating the relationship between topography and groundwater using outputs from a continental-scale integrated hydrology model. **Water Resources Research**, v. 51, p. 6602 – 6621, 2015.

CPRM - COMPANHIA DE PESQUISA DE RECURSOS MINERAIS. **Lençol freático**. Disponível: http://sigep.cprm.gov.br/glossario/verbete/lencol_freatico.htm. Acesso em: jun. de 2018.

CPRM - COMPANHIA DE PESQUISA DE RECURSOS MINERAIS. **Formação Serra Geral**. Disponível em: https://www.cprm.gov.br/publique/media/gestao_territorial/geoparques/Aparados/ap_geol_pag05.htm. Acesso em: maio de 2018.

CRABS et al. Modeling spatial patterns of saturated areas: A comparison of the topographic wetness index and a dynamic distributed model. **Journal of Hydrology**, v. 373, p. 15 – 23, 2009.

CROSBIE, R. S. et al. Estimating groundwater recharge and its associated uncertainty: Use of regression kriging and the chloride mass balance method. **Journal of Hydrology**, v. 561, p. 1 063-1080, 2018.

CRUZ, C. D. et al. **Modelos biométricos aplicados ao melhoramento genético**. 4 ed. Viçosa: Editora UFV, 2012. 514 p.

DAEE/SERH - DEPARTAMENTO DE ÁGUAS E ENERGIA Elétrica; IG/SMA - INSTITUTO GEOLÓGICO; IPT/SCTDE - INSTITUTO DE PESQUISAS TECNOLÓGICAS; CPRM - SERVIÇO GEOLÓGICO DO BRASIL. **Mapa de águas subterrâneas do Estado de São Paulo. Escala: 1:1.000.000.** São Paulo: Conselho Estadual de Recursos Hídricos, 2005.

DE LACO, S. et al. Radon Predictions with *Geographical Information System* Covariates: From Spatial Sampling to Modeling. **Geographical Analysis**, v. 49, p. 215 - 235, 2017.

DIAS, C. L. et al. A importância do monitoramento das águas subterrâneas na gestão dos recursos hídricos. In: **XV Congresso Brasileiro de Águas Subterrâneas.** Natal, 2008.

DIXON, B; UDDAMERI, V. **GIS and Geocomputation for Water Resource Science and Engineering.** West Sussex: Wiley, 2016. 568 p.

DURIGAN, G.; RATTER, J.A. Successional changes in cerrado and cerrado/forest ecotonal vegetation in western São Paulo State, Brazil, 1962-2000. **Edinburgh Journal of Botany**, v. 63. p. 119-130, 2006.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISAS AGROPECUÁRIA. **Sistema brasileiro de classificação de solos.** 2. ed. Rio de Janeiro: Embrapa Solos, 2006.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISAS AGROPECUÁRIA. **Caracterização dos solos em áreas experimentais com grevilea, no Estado do Paraná.** Colombo: Embrapa Florestas, 2011. 33 p.

EMBRAPA - EMPRESA BRASILEIRA DE PESQUISAS AGROPECUÁRIA. **Manual de métodos de análises de solo.** 2.ed. Rio de Janeiro: Ministério da Agricultura e do Abastecimento, 1997. 212 p.

ENGLUND, E. J.; SPARKS, A. R. **GEO-EAS (Geostatistical environmental assessment software) user's guide.** Washington: Battelle Columbus Labs, 1991. 132 p. Disponível em: <https://www.epa.gov/water-research/geostatistical-environmental-assessment-software-geo-eas>. Acesso em: jun. de 2018.

ESRI. **ArcGIS. v. 10.3.** Redlands: Esri, 2016.

FALKER. **Parâmetros para avaliação da resistência à penetração.** Disponível em: http://www.falker.com.br/download.php?file_id=84. Acesso em: jun. de 2018.

FETTER, C. W. **Applied hydrogeology.** 4th ed ed. Upper Saddle River, N.J: Prentice Hall, 2001.

FRANÇA, M. S. **Análise estatística multivariada dos dados de monitoramento de qualidade de água da Bacia do Alto Iguaçu:** uma ferramenta para a gestão de recursos hídricos. 150 f. 2009. Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambientais) – Universidade federal do Paraná, Curitiba, 2009.

FREEZE, R. A.; CHERRY, J. A. **Groundwater**. Englewood Cliffs, N.J: Prentice-Hall, 1979.

GAO, B.C. NDWI – A Normalized Difference Water Index for remote sensing of vegetation liquid water from space. **Remote Sensing of Environment**, v. 58, p. 257-266, 1996.

GE, Y. et al. Regression-kriging for characterizing soils with remote sensing data. **Frontiers of Earth Science**, v. 5, p. 239–244, 2011.

GHARBIA, S. S. et al. Spatially distributed potential evapotranspiration modeling and climate projections. **Science of The Total Environment**, v. 633, p. 571 – 592, 2018.

GIACOMIN, G. et al. Análise comparativa entre métodos interpoladores de modelos de superfícies. **Revista Brasileira de Cartografia**, v. 66, p. 1315-1329, 2014.

GOETTEN, W. J. **Avaliação da governança da água subterrânea nos Estados de São Paulo, Paraná, Santa Catarina e Rio Grande do Sul**. 320 f. 2015. Dissertação (Mestrado em Engenharia Ambiental) - Fundação Universidade Regional de Blumenau, Blumenau, 2015.

GOOVAERTS, P. Performance comparison of geostatistical algorithms for incorporating elevation into the mapping of precipitation. **GeoComputation**, p. 1 -18, 1999.

GUEDES, I. C. L. **Uso de métodos da estatística espacial em biometria e inventário florestal**. Tese (Doutorado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 2013.

HAN, W. S. et al. Local-scale variability in groundwater resources: Cedar Creek Watershed, Wisconsin, U.S.A. *Journal of Hydro-environment Research*, v. 20, p. 38 – 51, 2018.

HEALY, R. W.; COOK, P. G. Using groundwater levels to estimate recharge, **Journal of Hydrology**, v. 10, p. 91 – 109, 2002.

HEALY, R.W. **Estimating Groundwater Recharge**. Cambridge: University Press, 2010. 245 p.

HENGL, T. et al. **Comparison of kriging with external drift and regression-kriging**: Technical note, ITC. Enschede, 2003.

HENGL, T. et al. Methods to interpolate soil categorical variables from profile observations: lessons from Iran. **Geoderma**, Amsterdam, v.140, p. 417-427, 2007.

HENGL, T.; REUTER, H. I. **Geomorphometry**: Concepts, software, applications. *Developments in Soil Science*. Amsterdam: Elsevier, 2009, 765p.

HIRATA, R. et al. Águas subterrâneas: reserva estratégica ou emergencial. In: Bicudo, C. E.; Tundisi, J. G.; Scheuenstuhl, M. **Águas do Brasil: análises estratégicas**. 1ed. São Paulo: Instituto de Botânica, v. 1, 2010. p. 149-164.

HOLBEN, B. N. Characteristics of maximum-value composite images from temporal AVHRR data. **International Journal of Remote Sensing**, v. 7, n. 11, p.1417 - 1434, 1986.

HONDA, E. A.; NIZOLI, E. C. **Caracterização das águas da Estação Ecológica de Águas De Santa Bárbara**. Relatório Técnico. São Paulo: Instituto Florestal, 2005. 41 p.

HONGYU, K. et al. Análise de Componentes Principais: resumo teórico, aplicação e interpretação. **Engineering and Science**, v. 5, p. 83 – 90, 2015.

HUETE, A. R. A soil adjusted vegetation index (SAVI). **Remote Sensing of Environment**. v. 25. p. 295 – 309. 1988.

HUETE, A. R. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, v. 83, p. 195-213, 2002.

HUTCHINSON, M. F. A new procedure for gridding elevation and streamline data with automatic removal of spurious pits. **Journal of hydrology**, Amsterdam, v. 106, p. 211-232, 1989.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Pesquisa de Informações Básicas Estaduais (ESTADIC)**. Disponível em: https://biblioteca.ibge.gov.br/visualizacao/instrumentos_de_coleta/doc2886.pdf. Acesso em: maio de 2018.

IF - INSTITUTO FLORESTAL. **Plano de manejo da Estação Ecológica de Santa Barbara**. Disponível em: http://iflorestal.sp.gov.br/files/2013/03/Plano_de_Manejo_EEc_Santa_Barbara.pdf. Acesso em: maio de 2018.

IPT - INSTITUTO DE PESQUISAS TECNOLÓGICAS DO ESTADO DE SÃO PAULO. **Mapa geológico do Estado de São Paulo**. São Paulo. 1981. Escala 1:500,000.

ITESP - INSTITUTO DE TERRAS DO ESTADO DE SÃO PAULO. **Sítios e 'situantes': planejamento territorial e cálculo de módulo para assentamentos rurais**. 2 ed. São Paulo: FITESP, 2000.

IRITANI, M. A.; EZAKI, S. **As águas subterrâneas do Estado de São Paulo**. 3 ed. São Paulo: Secretaria do Estado do Meio Ambiente- SMA, 2012.

JAKEMAN, A. J. et al. Integrated Groundwater Management: An Overview of Concepts and Challenges. In: JAKEMAN, A. J. et al. (org). **Integrated Groundwater Management: Concepts, Approaches and Challenges**. Springer, 2016. 762 p.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente**: uma perspectiva em recursos terrestres. 2ed. São José dos Campos: Parêntese, 2009. 604 p.

Ji, L.; Zhang, L. et al. Analysis of Dynamic Thresholds for the Normalized Difference Water Index. **Photogrammetric Engineering and Remote Sensing**. v. 75, n. 11, p.1307-1317, 2009.

JIANG, Z. et al. Development of a two-band enhanced vegetation index without a blue band. **Remote Sensing of Environment**, v. 112, n. 10, p. 3833-3845, 2008.

JOHNSON, R. A.; WICHERN, D. W. **Applied multivariate statistical analysis**. New Jersey: Prentice-Hall, 1992. 642 p.

JOHNSTON, K. et al. **Using ArcGIS geostatistical analyst**. Redlands: ESRI, 2001. v. 380.

KARMANN, I. Ciclo da água: água subterrânea e sua ação geológica. In: TEIXEIRA, W. et al. (org). **Decifrando a Terra**. São Paulo. Oficina de Textos, 2003. 556 p.

KENDALL, M. G. **A course in multivariate analysis**. 2 ed. Charles Griffin, 1957. 210 p.

KIM, J. H. et al. Multivariate statistical analysis to identify the major factors governing groundwater quality in the coastal area of Kimje, South Korea. **Hydrological Processes**, v.19, n. 6, p. 1261-1276, 2005.

KLØVE, B. et al. Climate change impacts on groundwater and dependent ecosystems. **Journal of Hydrology**, v. 518, p. 250 – 266, 2014.

LATORRE, M. L. et al. Produtos para ecossistemas terrestres – MODLAND. In: RUDORFF, B. F. T. et al. (org.) **O sensor MODIS e suas aplicações ambientais no Brasil**. São José dos Campos: A. Silva Vieira Editora, 2007. p. 23-35.

LANDIM, P. M. B. **Análise estatística de dados geológicos**. São Paulo: Fundação Editora da Unesp, 2003.

LANDIM, P. M. B. Sobre Geoestatística e mapas. **Terra e Didática**, v. 2, n. 1, p. 19 – 33, 2006.

LEITE, M. E. et al. Sensoriamento remoto aplicado ao mapeamento da dinâmica do uso do solo na bacia do rio Pacuí, no norte de Minas Gerais, nos anos de 1989, 199 e 2009. **Revista do Departamento de Geografia da USP**, v. 23, p. 217-231, 2012.

LIU, W. T. H. **Aplicações de Sensoriamento Remoto**. 1 ed. Campo Grande: UNIDERP, 2006. 908 p.

LO, C.; YEUNG, A. K. **Concepts and techniques of geographic information systems**. 2 ed. Prentice Hall: Upper Saddle River, 2007. 544 p.

MACHADO, L. O. Variabilidade espacial de atributos químicos do solo em áreas sob sistema de plantio convencional. **Revista Brasileira de Ciências do Solo**, v. 31, p. 591 – 599, 2007.

MANCUSO, M. A.; CAMPOS, J. E. Aquífero Bauru. In: ROCHA, G. (coord). **Mapa de águas subterrâneas do Estado de São Paulo**: escala 1:1000000: nota explicativa. São Paulo. DAEE/SERH - DEPARTAMENTO DE ÁGUAS E ENERGIA ELÉTRICA; IG/SMA - INSTITUTO GEOLÓGICO; IPT/SCTDE - INSTITUTO DE PESQUISAS TECNOLÓGICAS; CPRM - SERVIÇO GEOLÓGICO DO BRASIL. São Paulo: Conselho Estadual de Recursos Hídricos, 2005.

MANOEL FILHO, J. Ocorrência das águas subterrâneas. In: FEITOSA et al. (org). **Hidrogeologia**: conceitos e aplicações. Rio de Janeiro. CPRM: LABHID, 2008. 812 p.

MANZIONE, R. L. et al. Relação entre a resposta espectral da vegetação em diferentes cultivos agrícolas e níveis freáticos em área de recarga do Sistema Aquífero Guarani. **Águas Subterrâneas**, v. 28, p. 1 – 13, 2014.

MANZIONE, R. L. **Águas Subterrâneas**: Conceitos e aplicações sob uma visão multidisciplinar. Jundiaí: Paco Editorial, 2015. 388 p.

MARINHO FILHO, G.M. et al. Modelos hidrológicos: conceitos e aplicabilidade. **Revista de Ciências Ambientais**, v.6, n.2, p. 35 – 47, 2013.

MARTINET, M. C. et al. On groundwater fluctuations, evapotranspiration, and understory removal in riparian corridors. **Water Resources Research**, v. 45, p. 1 – 19, 2009.

MATHERON, G. **The theory of regionalized variables and its applications**. Paris, Les Cahiers du Centre de Morphologie Mathématique de Fontainebleu, 1971. 211p.

MELLO, C. R. et al. Krigagem e inverso do quadrado da distância para interpolação dos parâmetros da equação de chuvas intensas. **Revista Brasileira de Ciência do Solo**, Campinas, v. 27, p. 925-933, 2003.

MELLO, J. M. Ajuste e seleção de modelos espaciais de semivariograma visando à estimativa volumétrica de *Eucalyptus grandis*. **Scientia Florestalis**, n. 69, p. 25 – 37, 2005.

MELLO, C.R. **Hidrologia**: Princípios e Aplicações. Lavras: UFLA, 2013. 455 p.

MENEZES, M. D. et al. Spatial prediction of soil properties in two contrasting physiographic regions in Brazil. **Scientia Agricola**, Piracicaba, v. 73, n. 3, p. 274-285, May/June 2016.

MINGOTI, S.A. **Análise de dados através de métodos de estatística multivariada**: uma abordagem aplicada. Editora UFMG, Belo Horizonte, 2005. 297 p.

MILONE, G.; ANGELINI, F. **Estatística aplicada**. São Paulo: Atlas, 1995. 286 p.

MILLAR, D. J. et al. Groundwater dynamics in mountain peatlands with contrasting climate, vegetation, and hydrogeological setting. **Journal of Hydrology**, v. 561, p. 908 – 917, 2018.

MINITAB INC. (2018). **Minitab 16**. State College: Minitab Inc, 2018.

MINITAB INC. **Interpretação das estatísticas as estatísticas para regressão dos melhores subconjuntos**. Disponível em: <https://support.minitab.com/pt-br/minitab/18/help-and-how-to/modeling-statistics/regression/how-to/best-subsets-regression/interpret-the-results/all-statistics/>. Acesso em: maio de 2018.

MOORE, I. D. et al. Digital terrain modelling: a review of hydrological, geomorphological, and biological applications. **Hydrological Processes**, v. 5, p. 3 - 30, 1991.

MORAES, D. A. C. **Simulação sequencial na interpolação dos dados de entrada ou saída do modelo de lixiviação do software ARAQUÁ**. 75 f. 2015. Tese (Doutorado em Agronomia) - Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, Botucatu, 2015.

MORAES, E. C. Fundamentos do sensoriamento remoto. IN: DI MAIO, A. et al. (org). **Sensoriamento Remoto**. INPE, 2008. 82 p.

MOTA, V. C. **Metodologia geoestatística para caracterizar a variabilidade temporal de elementos climáticos de Juiz de Fora – MG**. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) – Universidade Federal de Lavras, Lavras, 2008.

ODEH, I. O. A. et al. Further results on prediction of soil properties from terrain attributes: heterotopic cokriging and regression-kriging. **Geoderma**, Amsterdam, v. 67, n. 3/4, p. 215-226, 1995.

OLIVEIRA, J. B. **Solos do estado de São Paulo: descrição das classes registradas no mapa pedológico**. Bol. Ci. n, 45, Campinas/SP: IAC, 1999. 63p.

OLIVEIRA, M. C. N. **Métodos de estimação de parâmetros em modelos geoestatísticos com diferentes estruturas de covariâncias: uma aplicação ao teor de cálcio no solo**. Tese (Doutorado em Agronomia) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2003.

OLIVEIRA, P.T.S. et al., Geoprocessamento como ferramenta no licenciamento ambiental de postos de combustíveis. **Sociedade & Natureza**, v. 20, p. 87 – 99, 2008

OLIVEIRA, P. C. G. et al. Variabilidade espacial de propriedades químicas do solo e da produtividade de citros na Amazônia Oriental. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 13, n. 6, p. 708-715, 2009.

OMUTO, C. T.; VARGAS, R. R. Re-tooling of regression-kriging in R for improved digital mapping of soil properties. **Geosciences Journal**, v. 19, n. 1, p. 157-165, 2015.

OSCO, L. P. et al. Comparação entre índices de vegetação obtidos por diferentes modelos de correção atmosférica para a avaliação de biomassa em culturas de laranjas-pêra. In: **IV Simpósio Brasileiro de Geomática/ II Jornadas Lusófonas sobre Ciências e Tecnologias de Informação Geográfica/CTIG**. Anais do IV Simpósio Brasileiro de Geomática / II Jornadas Lusófonas sobre Ciências e Tecnologias de Informação Geográfica/CTIG. Presidente Prudente: FTC-UNESP, 2017. v. 1. p. 251-257.

PAULA E SILVA, F. et al. Estudo estratigráfico do Grupo Bauru na região de Presidente Prudente com base em perfis geofísicos de poços para água. **Revista Geociências**, v.13, n.1, p. 63- 81, 1994.

PAULA E SILVA, F. et al. Estratigrafia de superfície do Grupo Bauru (K) no Estado de São Paulo. **Revista Brasileira de Geociências**, v. 35, n.1, p. 77 – 88, 2005.

PEREIRA, N. S. et al. A Importância do Geoprocessamento para a História e o Saber Ambiental. **Journal of Social, Technological and Environmental Science**, v. 3, n. 2, p.132-144, 2014.

PONZONI, F. J.; SANTOS, S. B. Conversão de números digitais de imagens orbitais em valores de FRB de superfície. **Boletim de Ciências Geodésicas**, Curitiba, v. 14, n. 4, p. 541-556, 2008.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento Remoto no Estudo da Vegetação**. São José dos Campos: Parêntese, 2010.

PORTO, M. F. A; PORTO, R. L. Gestão de bacias hidrográficas. **Estudos Avançados**, v. 22, n. 63, p. 43-60, 2008.

PÖSCHKE, F. et al. How does the groundwater influence the water balance of a lowland lake? A field study from Lake Stechlin, north-eastern Germany. **Limnologia**, v. 68, p. 17-25, 2018.

PRASANNA et al. Statistical analysis of the hydrogeochemical evolution of groundwater in hard and sedimentary aquifers system of Gadilam river basin, South India. **Journal of King Saud University**, v. 22, p. 133-145, 2010.

QGIS DEVELOPMENT TEAM. **QGIS**. Software, Versão 2.14.8. Disponível em: <<http://qgis.org/>> Acesso em ago/2016.

REBOUÇAS, A. C. Águas subterrâneas. In: REBOUÇAS, A. et al. (org). **Águas doces no Brasil: capital ecológico, uso e conservação**. São Paulo: Escrituras, 2002. 703p.

RENNÓ, C.D.; SOARES, J.V. **Modelos Hidrológicos para Gestão Ambiental**.

Disponível em:

http://www.dpi.inpe.br/geopro/modelagem/relatorio_modelos_hidrologicos.pdf.

Acesso em: maio de 2018.

ROUSE, J.W. et al. Monitoring vegetation systems in the Great Plains with ERTS. In: **3rd ERTS Symposium**, NASA. 1973.

SAITO, N. S. Modelos digitais de elevação no estudo de bacias hidrográficas. In: SANTOS, A. R et al. (org). **Geotecnologias aplicadas aos recursos florestais**. CAUFES, 2012. 249 p.

SAGA GIS DEVELOPMENT TEAM. **System for Automated Geoscientific Analyses**

(SAGA GIS). Software, Versão 2.2.2. Disponível em <<http://www.sagagis.org/>>

Acesso

em nov/2016.

SALLES, L. M. S. Environmental factors and groundwater behavior in an agricultural experimental basin of the Brazilian central plateau. **Applied Geography**, v. 94, p. 272-281, 2018.

SANTAROSA, L. V. **Mapeamento dos níveis freáticos do Sistema Aquífero Bauru (SAB) em área de proteção ambiental em Águas de Santa Bárbara/SP durante o ano hidrológico 2014/2015**. 104 f. 2016. Dissertação (Mestrado em Agronomia) – Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu, 2016.

SANTAROSA, L. V.; MANZIONE, R. L. Modelo Hidrogeológico Conceitual da Estação Ecológica de Santa Bárbara (EEcSB) em área do Sistema Aquífero Bauru (SAB). **Águas Subterrâneas**, v. 31, n. 4, p. 404-412, 2017.

SANTOS, R. D. et al. **Manual de descrição e coleta de solo no campo**.

Viçosa/MG: Sociedade Brasileira de Ciência do Solo, 2005.

SASSI, C. P. et al. **Modelos de regressão linear múltipla utilizando os softwares R e Statistica: uma aplicação a dados de conservação de frutas**. São Carlos: ICMC-USP, n. 377, 2012. Disponível em:

http://conteudo.icmc.usp.br/CMS/Arquivos/arquivos_enviados/BIBLIOTECA_113_RT_377.pdf. Acesso em: ago. de 2016.

SAVI, E. L. **Avaliação do nível de oxidação do biodiesel e quantificação do biodiesel em blendas via métodos espectroscópicos**. 115 f. 2017. Tese (Doutorado em Física) – Centro de Ciências Exatas, Universidade Estadual de Maringá, Maringá, 2017.

SCOLFORO, H. F. **Interpoladores espaciais na estimativa da distribuição do estoque de carbono da vegetação arbórea em Minas Gerais, Brasil**. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal de Lavras, Lavras, 2014.

SILVA, F. P. et al. Hidroestratigrafia do Grupo Bauru (K) no Estado de São Paulo. **Águas Subterrâneas**, v.19, n.2, p.19-36, 2005.

SILVA, S. R.; CHANG, H. K. Hidroquímica dos Sistemas Aquíferos Bauru e Guarani na Região Metropolitana de Bauru (SP). **Águas Subterrâneas**, v.24, n.1, p.69-84, 2010.

SIGRH - SISTEMA INTEGRADO DE GERENCIAMENTO DE RECURSOS HÍDRICOS DO ESTADO DE SÃO PAULO. **Geomorfologia**: mapa geomorfológico do Estado de São Paulo. Disponível em: http://www.sigrh.sp.gov.br/public/uploads/documents/6382/i_2_2geomorfologia.pdf. Acesso em: jun. de 2018.

SOARES, P. C. et al. Ensaio de caracterização estratigráfica do Cretáceo no Estado de São Paulo: Grupo Bauru. **Revista Brasileira de Geociências**, p. 177 – 185, 1980.

SOARES, A. **Geoestatística para as ciências da terra e do ambiente**. Lisboa: Instituto Superior Técnico, 2006. 214 p.

TEIXEIRA, D. B. et al. Avaliação da krigagem ordinária e simulação sequencial gaussiana na interpolação da emissão de CO₂ do solo. In: **II Simpósio de Geoestatística Aplicada em Ciências Agrárias**. Anais do II Simpósio de Geoestatística Aplicada em Ciências Agrárias. Botucatu: Fepaf, 2011. p. 1 - 6.

TEIXEIRA, M. R. **A utilização do geoprocessamento na análise ambiental e sua importância na tomada de decisões**: Um estudo do geoprocessamento em pesquisas sobre ocupação desordenada do solo. 40 f. 2015. Certificado de Conclusão de Curso (Pós-graduação *Lato Sensu* em Análise ambiental e Desenvolvimento Sustentável). Instituto CEUB de Pesquisa e Desenvolvimento, Centro Universitário de Brasília, Brasília, 2015.

TOBLER, W. R. A Computer Movie Simulating Urban Growth in the Detroit Region. **Economic Geography**, v. 46, p. 234, jun. 1970.

TODD, D. K.; MAYS, L. W. **Groundwater hydrology**. 3rd ed ed. Hoboken, NJ: Wiley, 2005.

TRANGMAR, B.B. et al. Applications of geostatistics to spatial studies of soil properties. **Advances in Agronomy**, v. 38, p.45-94, 1985.

TUCCI, C. E. M. **Modelos hidrológicos**. 2 ed. Porto Alegre: Associação Brasileira de Recursos Hídricos / Editora da UFRGS, 2005. 678p.

USGS - UNITED STATES GEOLOGICAL SURVEY. **Landsat 8**. Disponível em: <https://landsat.usgs.gov/landsat-8-mission>. Acesso em: jul. de 2018.

VEEGER, A.I.; JOHNSTON, H.E. **Hydrogeology and water resources of Block Island, Rhode Island**. U.S. Geological Survey Water-Resources Investigations Report, v. 94, 1996.

VEIGA, T. C.; SILVA, J. X. Geoprocessamento aplicado à identificação de áreas potenciais para atividades turísticas: O caso do Município de Macaé – RJ. In: SILVA, J. X.; ZAIDAN, R. T. (Org.) **Geoprocessamento & Análise ambiental**. Rio de Janeiro: Bertrand Brasil, p.179-215, 2004.

VICENTE, J. **Estudo comparativo de métodos geoestatísticos aplicados em agricultura de precisão**. 163 f. 2004. Dissertação (Mestrado em Ciências Cartográficas) – Faculdade de Ciência e Tecnologia, Universidade Estadual Paulista, Presidente prudente, 2004.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R. F. et al. **Tópicos em Ciência do Solo**. Sociedade Brasileira de Ciência do Solo, v.1, p.1-54, 2000.

VON ASMUTH, J. R. et al. Transfer function noise modelling in continuous time using predefined impulse response functions. **Water Resources Research**, v. 38, n.12, p. 23.1-23.12, 2002.

VON ASMUTH, J. R.; KNOTTTERS, M. Characterising groundwater dynamics based on a system identification approach. **Journal of Hydrology**, v. 296, p. 118-34, 2004.

XI, H. Y. et al. Impacts of river recharge on groundwater level and hydrochemistry in the lower reaches of Heihe River Watershed, northwestern China. **Hydrogeology Journal**, v. 18, p. 791 – 801, 2010.

WANG, F. K.; DU, T. C. T. Using principal component analysis in process performance for multivariate data. **The International Journal of Management Science**, v. 28, p. 185 – 194, 2000.

WINTER, T. C. et al. **Ground water and surface water a single resource**. U.S. Geological Survey, Denver, 1998.

YAMAMOTO, J.K.; LANDIM, P.M.B. **Geoestatística: conceitos e aplicações**. São Paulo: Oficina de textos, 2013. 215p.

YAN, S. et al. Understanding groundwater table using a statistical model. **Water Science and Engineering**, v. 11, p. 1 – 7, 2018.

APÊNDICE A - Resultado das análises granulométricas.

ID	Areia	Argila	Silte	Fração de areia (%)			K (m/dia)	RP (kPa)	
	%			Muito Fina	Fina	Media			Grossa
G1	80,96	18,20	0,84	15,71	48,88	33,04	2,38	3,80	927,91
G2	87,04	10,80	2,16	13,49	48,32	35,28	2,91	3,84	858,79
G3	85,67	11,70	2,63	10,89	46,37	39,02	3,72	4,93	926,98
G4	84,89	12,60	2,51	10,92	50,19	36,24	2,65	4,11	1.059,44
G5	86,29	11,70	2,01	12,16	53,63	32,46	1,75	3,74	1.648,72
G6	92,80	6,60	0,60	12,74	48,49	34,34	4,43	4,38	1.890,00
G7	84,56	14,60	0,84	10,71	44,24	37,42	7,64	4,84	734,49
G8	86,48	12,80	0,72	10,02	44,42	40,73	4,83	7,50	786,50
G9	-	-	-	-	-	-	-	-	458,00
G10	82,85	16,50	0,65	15,80	51,87	30,35	1,98	4,71	669,95
B1	79,44	19,80	0,76	12,26	47,94	36,98	2,83	3,60	657,33
B2	81,96	17,60	0,44	18,58	54,28	25,84	1,30	3,88	580,00
B3	84,00	15,30	0,70	12,73	48,98	34,93	3,35	4,93	1.135,79
B4	86,70	12,70	0,60	12,65	48,01	36,79	2,55	7,14	985,81
B5	87,67	11,40	0,93	11,37	45,64	39,31	3,69	9,53	553,67
B6	86,69	12,20	1,11	17,23	53,13	28,07	1,56	8,95	1.598,33
B7	85,44	14,00	0,56	14,29	53,46	31,08	1,17	5,07	844,54
B8	-	-	-	-	-	-	-	-	1.126,00
B9	80,68	17,80	1,52	13,10	52,91	32,19	1,81	11,14	1.017,52
B10	79,54	20,00	0,46	12,96	51,60	33,60	1,84	3,95	924,67
B11	-	-	-	-	-	-	-	-	1.094,00
B12	81,25	18,20	0,55	13,28	51,25	33,77	1,70	4,16	742,97
S1	-	-	-	-	-	-	-	-	-
S2	84,42	13,70	1,88	10,17	47,76	39,15	2,92	5,01	1.039,08
S3	84,89	13,30	1,81	8,81	47,65	40,00	3,54	4,56	1.019,50
S4	75,48	22,60	1,92	10,04	39,01	44,14	6,82	5,16	1.153,00
S5	82,74	17,00	0,26	13,85	50,36	33,22	2,57	4,89	849,00
S6	84,07	13,60	2,33	11,80	48,02	34,99	4,31	3,68	522,00
S7	88,80	8,40	2,80	13,93	44,69	38,11	3,26	3,67	824,00
S8	92,43	5,00	2,57	8,84	44,82	42,40	3,94	3,80	1.501,00
S9	83,80	14,40	1,81	15,78	44,49	36,23	3,50	3,88	1.740,00
S10	83,92	14,80	1,28	11,29	37,46	43,24	8,01	3,66	1.302,00
S11	88,77	10,00	1,23	15,19	47,65	34,35	2,81	4,09	867,00
S12	83,83	14,60	1,58	18,75	54,20	25,83	1,21	5,17	550,43
S13	88,47	9,30	2,23	15,43	47,91	33,92	2,65	5,87	927,30
S14	77,47	20,47	2,07	20,87	51,31	26,25	1,57	6,09	917,49
S15	87,63	10,50	1,87	13,27	47,18	36,61	2,94	6,92	708,48
S16	-	-	-	-	-	-	-	-	1.184,80
S17	90,91	7,20	1,89	17,70	50,92	29,79	1,59	8,10	709,83

(continua...)

P1	91,10	7,30	1,60	8,18	47,36	41,73	2,73	6,27	649,54
P2	90,16	8,30	1,54	13,63	43,71	37,95	4,40	4,78	1.161,58
P3	87,36	11,40	1,24	15,00	50,65	31,61	2,75	4,55	1.627,67
BOI_D	-	-	-	-	-	-	-	-	1.433,80
BOI1	80,73	17,90	1,37	14,72	48,49	34,33	2,45	4,62	1.081,61
BOI2	79,03	18,80	2,17	12,34	45,59	38,83	3,23	5,70	1.341,48
BOI3	81,61	16,20	2,19	11,97	45,01	39,38	3,64	5,41	1.116,79
BOI4	80,03	18,30	1,67	13,37	44,47	39,11	3,05	4,85	904,57
BOI5	78,62	19,00	2,38	16,07	47,47	34,32	2,14	4,69	826,66
BOI6	81,08	16,50	2,42	16,25	50,48	31,30	1,98	4,83	860,98
BOI7	85,25	13,20	1,55	15,83	55,47	25,05	3,65	8,26	676,33
BOI8	79,89	18,80	1,31	13,14	49,53	34,77	2,56	4,84	997,00
BR1	89,95	9,20	0,85	10,32	45,03	41,92	2,73	19,31	554,00
BR2	89,95	9,20	0,85	10,32	45,03	41,92	2,73	19,31	842,00
BR3	89,95	9,20	0,85	10,32	45,03	41,92	2,73	19,31	879,00
BR4	89,95	9,20	0,85	10,32	45,03	41,92	2,73	19,31	450,00
BR5	89,95	9,20	0,85	10,32	45,03	41,92	2,73	19,31	763,00

APÊNDICE B – Variáveis obtidas em SIG.

ID	Elevação (m)	Declividade (%)	NDVI	SAVI	EVI	NDWI	ITU
G1	637,93	2,07	0,74	0,37	0,30	0,14	14,33
G2	640,36	0,60	0,60	0,31	0,22	-0,07	13,95
G3	650,37	1,68	0,56	0,29	0,21	-0,07	13,95
G4	651,37	1,58	0,57	0,28	0,20	-0,13	13,95
G5	650,36	1,87	0,56	0,28	0,20	-0,10	13,95
G6	648,12	1,78	0,61	0,33	0,24	0,01	14,75
G7	653,90	1,19	0,82	0,40	0,34	0,36	14,76
G8	656,37	0,69	0,74	0,29	0,24	0,16	14,99
G9	654,94	1,00	0,87	0,44	0,39	0,33	15,45
G10	651,93	0,66	0,61	0,33	0,24	0,03	15,32
B1	642,96	4,94	0,69	0,35	0,27	0,19	12,97
B2	654,47	3,54	0,84	0,34	0,28	0,17	12,97
B3	653,27	3,89	0,73	0,37	0,29	0,22	12,97
B4	642,99	4,56	0,79	0,35	0,29	0,25	13,70
B5	642,93	3,81	0,83	0,41	0,34	0,22	13,96
B6	656,13	2,54	0,67	0,33	0,25	0,22	13,19
B7	658,09	1,48	0,81	0,38	0,32	0,27	12,97
B8	655,87	1,63	0,65	0,36	0,30	0,38	12,97
B9	640,70	2,80	0,69	0,34	0,26	0,06	13,75
B10	638,26	0,55	0,69	0,39	0,32	0,23	18,93
B11	636,53	0,50	0,69	0,34	0,26	0,03	15,96
B12	637,31	0,73	0,74	0,37	0,29	0,05	14,29
S1	638,99	0,47	0,67	0,38	0,29	0,14	18,03
S2	639,59	0,57	0,79	0,42	0,35	0,22	13,95
S3	640,36	0,95	0,76	0,36	0,29	0,12	13,95
S4	639,68	0,49	0,65	0,32	0,24	0,03	15,55
S5	648,10	2,48	0,67	0,36	0,27	0,05	13,55
S6	649,09	2,45	0,72	0,35	0,27	0,03	13,40
S7	639,92	0,44	0,70	0,34	0,26	0,06	14,33
S8	639,60	0,47	0,84	0,40	0,34	0,40	14,62
S9	639,53	0,25	0,83	0,39	0,33	0,38	19,13
S10	639,39	0,21	0,83	0,39	0,33	0,40	19,18
S11	638,82	0,32	0,75	0,37	0,30	0,15	15,55
S12	637,03	0,98	0,73	0,34	0,27	0,01	15,88
S13	634,96	1,15	0,72	0,36	0,28	0,10	13,82
S14	639,17	1,56	0,49	0,24	0,17	-0,15	13,82
S15	636,80	1,23	0,66	0,33	0,25	-0,02	12,86
S16	639,43	0,97	0,47	0,28	0,19	-0,01	13,66
S17	639,87	0,39	0,63	0,31	0,23	-0,03	16,16

(continua...)

P1	656,75	0,99	0,82	0,39	0,33	0,36	14,19
P2	659,23	1,43	0,75	0,37	0,30	0,24	13,43
P3	657,97	1,60	0,85	0,37	0,31	0,36	13,99
BOI_D	639,81	0,52	0,62	0,31	0,23	-0,06	13,65
BOI1	640,00	0,28	0,71	0,34	0,26	0,03	13,65
BOI2	639,01	0,52	0,69	0,38	0,30	0,14	13,67
BOI3	639,64	0,45	0,67	0,32	0,24	-0,01	15,96
BOI4	639,27	0,69	0,75	0,35	0,28	0,11	12,97
BOI5	637,94	0,62	0,73	0,35	0,28	0,13	13,48
BOI6	639,14	0,69	0,75	0,38	0,30	0,14	14,63
BOI7	638,37	0,68	0,69	0,33	0,25	0,02	15,14
BOI8	638,44	0,77	0,74	0,36	0,28	0,10	13,04
BR1	658,45	1,84	0,79	0,37	0,30	0,16	13,89
BR2	658,45	1,84	0,79	0,38	0,31	0,18	13,89
BR3	657,96	1,91	0,79	0,39	0,32	0,19	14,02
BR4	657,96	1,91	0,79	0,38	0,31	0,15	14,02
BR5	657,97	1,83	0,78	0,38	0,31	0,16	12,59

APÊNDICE C – Valores relativos ao monitoramento dos poços.

ID	Nível	Nível médio	Nível		Distância	Temperatura (°C)
			máximo	mínimo		
	metros (m)					
G1	-0,04	-0,44	-0,04	-0,85	5,78	19,4
G2	-0,89	-0,61	-0,28	-1,16	78,52	18,8
G3	-0,59	-0,50	-0,31	-0,76	45,53	19,8
G4	-1,12	-1,01	-0,63	-1,43	43,68	20,6
G5	-1,57	-1,47	-1,19	-2,01	39,84	20,2
G6	-0,48	-0,79	-0,24	-4,2	45,73	19,7
G7	0	-0,24	0	-0,41	39,85	20,2
G8	0	-0,06	0	-0,22	116,52	18,6
G9	-0,08	-0,09	0	-0,35	49,43	19,4
G10	-4,29	-5,20	-3,44	-7,35	577,54	21,3
B1	-0,52	-0,61	-0,45	-0,82	53,26	19,5
B2	0	0,00	0	-0,16	57,11	19,9
B3	-0,04	-0,05	0	-0,15	28,30	19,4
B4	-0,49	-0,28	0	-0,63	38,75	18,8
B5	-0,1	-0,22	0	-0,73	66,16	18,8
B6	-0,25	-0,18	0	-0,4	87,80	18,4
B7	-0,56	-0,40	-0,1	-1,02	242,73	18,9
B8	-1,04	-0,80	-0,48	-1,22	118,48	19,4
B9	-0,13	-0,25	0	-0,53	13,57	18,4
B10	-0,01	-0,02	0	-0,18	14,09	18
B11	-1,44	-1,34	-0,81	-1,63	86,35	19,1
B12	-3,01	-3,14	-2,43	-4,67	93,26	21,2
S1	-0,44	-0,32	0	-0,84	40,74	20
S2	-3,58	-3,55	-3,03	-4,17	46,40	22,5
S3	-3,07	-2,88	-2,27	-3,53	91,24	22,5
S4	-0,63	-0,62	-0,42	-0,88	46,89	19,6
S5	-0,24	-0,31	-0,15	-0,47	45,98	20,3
S6	-0,41	-0,48	-0,36	-0,66	19,27	20,9
S7	-0,05	-0,05	0,04	-0,24	81,73	20,1
S8	-1,56	-1,50	-0,68	-2,08	37,81	21,5
S9	-0,69	-0,70	0	-2,18	8,16	20,3
S10	-0,99	-0,91	-0,28	-1,23	3,09	20
S11	-1,41	-1,13	-0,57	-1,68	57,40	21,1
S12	-2,28	-2,10	-1,5	-2,92	119,33	21
S13	-0,41	-0,37	0	-0,68	26,35	19,1
S14	-4,91	-4,36	-2,3	-5,39	181,93	21,4
S15	-1,21	-1,12	-0,69	-1,63	51,34	20,2
S16	-2,02	-1,89	-0,62	-2,94	78,33	21,1
S17	-1,48	-1,42	-0,67	-2,56	58,20	20,3

(continua...)

P1	-0,42	-0,45	-0,32	-0,71	213,51	19,4
P2	-0,88	-0,84	-0,21	-1,83	548,13	19,7
P3	-0,94	-0,82	-0,17	-1,8	469,99	19,9
BOI_D	-2,24	-2,13	-1,5	-3,3	85,95	21
BOI1	-0,74	-0,70	-0,39	-1,27	102,71	19,6
BOI2	-0,32	-0,29	-0,09	-0,52	22,98	19
BOI3	-1,71	-1,72	-1,57	-2,05	2,11	21,7
BOI4	-0,05	-0,17	0	-0,48	59,75	18
BOI5	-1,34	-1,32	-1,05	-1,56	74,95	20,5
BOI6	-1,23	-1,24	-1,02	-1,54	26,67	21,8
BOI7	-0,48	-0,61	-0,26	-1,24	31,61	20
BOI8	-1,4	-1,53	-1,25	-1,88	4,54	21
BR1	-0,49	-0,85	0	-1,86	656,14	20
BR2	-0,32	-0,83	0	-1,83	674,09	19
BR3	-0,5	-0,85	0	-1,84	668,07	20,1
BR4	-0,5	-0,85	0	-1,84	686,63	20,1
BR5	-0,48	-0,81	0	-1,82	690,54	20,4
