



**JULIANA DE SOUSA RIBEIRO**

**MODELO NEURO-FUZZY PARA PREDIÇÃO  
DE ATRIBUTOS DE SOLO EM ÁREAS  
DEGRADADAS E SOB AGRICULTURA DE  
PRECISÃO**

**LAVRAS - MG**

**2013**

**JULIANA DE SOUSA RIBEIRO**

**MODELO NEURO-FUZZY PARA PREDIÇÃO DE ATRIBUTOS DE  
SOLO EM ÁREAS DEGRADADAS E SOB AGRICULTURA DE  
PRECISÃO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, área de concentração em Modelagem de Sistemas Biológicos, para a obtenção do título de Mestre.

Orientador

Dr. Francisco Carlos Gomes

Coorientador

Dr. Luiz Roberto Guimarães Guilherme

**LAVRAS - MG**

**2013**

**Ficha Catalográfica Elaborada pela Coordenadoria de Produtos e  
Serviços da Biblioteca Universitária da UFLA**

Ribeiro, Juliana de Sousa.

Modelo neuro fuzzy para predição de atributos de solo em áreas degradadas e sob agricultura de precisão / Juliana de Sousa Ribeiro.

– Lavras : UFLA, 2013.

110 p. : il.

Dissertação (mestrado) – Universidade Federal de Lavras, 2013.

Orientador: Francisco Carlos Gomes.

Bibliografia.

1. Simulação. 2. Neuro fuzzy. 3. Áreas degradadas. 4. Redes neurais. I. Universidade Federal de Lavras. II. Título.

CDD – 620.00113

**JULIANA DE SOUSA RIBEIRO**

**MODELO NEURO-FUZZY PARA PREDIÇÃO DE ATRIBUTOS DE  
SOLO EM ÁREAS DEGRADADAS E SOB AGRICULTURA DE  
PRECISÃO**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas, área de concentração em Modelagem de Sistemas Biológicos, para a obtenção do título de Mestre.

APROVADA em 16 de setembro de 2013.

Dr. Roberto Alves Braga Junior      UFLA

Dr. Tadayuki Yanagi Junior      UFLA

Dr. Danton Diego Ferreira      UFLA

Dr. Francisco Carlos Gomes

Orientador

Dr. Luiz Roberto Guimarães Guilherme

Coorientador

**LAVRAS - MG**

**2013**

*Dedico este trabalho aos familiares e amigos pela compreensão de minha  
ausência.*

## **AGRADECIMENTOS**

Agradeço à todos que deram sua contribuição para realização deste estudo.

## RESUMO

Este trabalho tem como objetivo o desenvolvimento um *software* para simulação de atributos em estudos para mapeamento de solos, enfatizando a importância em auxiliar o meio ambiente a se recuperar das ações e impactos negativos do homem. Foi criado um sistema de simulação neuro-*fuzzy* adaptativo para simular atributos do solo, a partir de dados de análises realizadas em laboratório. O modelo neuro-*fuzzy* adaptativo mostrou-se representativo com 78% e 80% nas áreas de agricultura de precisão, denotando sua eficiência para um conjunto maior de amostras coletadas.

Palavras-chave: Simulação. Neuro-*fuzzy*. Redes Neurais. Áreas Degradadas.

## **ABSTRACT**

This work aims to develop a software for simulation attributes for soil mapping studies, emphasizing the importance of helping the environment to recover from actions and negative impacts of man. A system simulation neural-fuzzy adaptive to simulate soil attributes based on data analyzes in the laboratory. And in the end it is observed that the simulation could represent 80% of the samples collected in areas of precision agriculture.

**Keywords:** Simulation. Neural-Fuzzy. Neural Networks. Degraded Areas.

## LISTA DE FIGURAS

Figura 1	Passos em um estudo envolvendo a modelagem e simulação (FREITAS, 2008) .....	21
Figura 2	Modelo não linear de um neurônio artificial .....	22
Figura 3	Redes alimentadas adiante com camada única .....	27
Figura 4	Redes alimentadas diretamente com múltiplas camadas .....	28
Figura 5	Rede recorrente com neurônios ocultos .....	29
Figura 6	Arquitetura neuro- <i>fuzzy</i> .....	32
Figura 7	Fluxo de procedimentos reabilite .....	41
Figura 8	Página inicial do REABILITE .....	43
Figura 9	Arquitetura de banco de dados .....	44
Figura 10	Sistema neuro- <i>fuzzy</i> .....	46
Figura 11	Arquitetura do sistema neuro- <i>fuzzy</i> .....	49
Figura 12	Delimitação da área 1 .....	52
Figura 13	Pontos simulados na área 1 .....	53
Figura 14	Resultados da 1a área simulada.....	55
Figura 15	Delimitação da área 2 .....	56
Figura 16	Pontos simulados na área 2 .....	57
Figura 17	Resultados da 2a área simulada.....	58
Figura 18	Delimitação da área 3 .....	59
Figura 19	Pontos simulados na área 3 .....	60
Figura 20	Resultados da 3a área simulada.....	61
Figura 21	Classificação dos valores .....	64
Figura 22	1a área - Variabilidade do <i>ph</i> original.....	65
Figura 23	Variabilidade do <i>ph</i> simulado - 1a área .....	65
Figura 24	Variabilidade do <i>p-rem</i> original- 1a área .....	66
Figura 25	Variabilidade do <i>p-rem</i> simulado - 1a área .....	67
Figura 26	Variabilidade do <i>p</i> original - 1a área .....	68
Figura 27	Variabilidade do <i>p</i> simulado - 1a área .....	68
Figura 28	Variabilidade do <i>k</i> original- 1a área.....	69
Figura 29	Variabilidade do <i>k</i> simulado - 1a área.....	70

Figura 30	Variabilidade do <i>Na</i> original - 1a área.....	71
Figura 31	Variabilidade do <i>Na</i> simulado - 1a área.....	71
Figura 32	Variabilidade do <i>Ca</i> original- 1a área.....	72
Figura 33	Variabilidade do <i>Ca</i> simulado - 1a área.....	73
Figura 34	Variabilidade do <i>Mg</i> original- 1a área.....	74
Figura 35	Variabilidade do <i>Mg</i> simulado - 1a área.....	74
Figura 36	Variabilidade do <i>Al</i> original - 1a área.....	75
Figura 37	Variabilidade do <i>Al</i> simulado - 1a área.....	76
Figura 38	Variabilidade do <i>H+Al</i> original - 1a área.....	77
Figura 39	Variabilidade do <i>H+Al</i> simulado - 1a área.....	77
Figura 40	Variabilidade do <i>SB</i> original - 1a área.....	78
Figura 41	Variabilidade do <i>SB</i> simulado - 1a área.....	79
Figura 42	Variabilidade do <i>t</i> original- 1a área.....	80
Figura 43	Variabilidade do <i>t</i> simulado - 1a área.....	80
Figura 44	Variabilidade do <i>T</i> original - 1a área.....	81
Figura 45	Variabilidade do <i>T</i> simulado - 1a área.....	82
Figura 46	Variabilidade do <i>V</i> original - 1a área.....	83
Figura 47	Variabilidade do <i>V</i> simulado - 1a área.....	83
Figura 48	Variabilidade do <i>m</i> simulado - 1a área.....	84
Figura 49	Variabilidade do <i>m</i> simulado - 1a área.....	85
Figura 50	Variabilidade do <i>MO</i> original - 1a área.....	86
Figura 51	Variabilidade do <i>MO</i> simulado - 1a área.....	86
Figura 52	Variabilidade do <i>B</i> original - 1a área.....	87
Figura 53	Variabilidade do <i>B</i> simulado - 1a área.....	88
Figura 54	Variabilidade do <i>S</i> original - 1a área.....	89
Figura 55	Variabilidade do <i>S</i> simulado - 1a área.....	89
Figura 56	Variabilidade do <i>CE</i> original - 1a área.....	90
Figura 57	Variabilidade do <i>CE</i> simulado - 1a área.....	91
Figura 58	Variabilidade do <i>Ph</i> original - 2a área.....	92
Figura 59	Variabilidade do <i>Ph</i> simulado - 2a área.....	92
Figura 60	Variabilidade do <i>K</i> original - 2a área.....	93
Figura 61	Variabilidade do <i>K</i> simulado - 2a área.....	93
Figura 62	Variabilidade do <i>Ca</i> original - 2a área.....	94
Figura 63	Variabilidade do <i>Ca</i> simulado - 2a área.....	94

Figura 64	Variabilidade do <i>Mg</i> original - 2a área .....	95
Figura 65	Variabilidade do <i>Mg</i> simulado - 2a área .....	95
Figura 66	Variabilidade do <i>H+Al</i> original - 2a área.....	97
Figura 67	Variabilidade do <i>H+Al</i> simulado - 2a área.....	98
Figura 68	Variabilidade do <i>MO</i> original - 2a área .....	98
Figura 69	Variabilidade do <i>MO</i> simulado - 2a área .....	99
Figura 70	Variabilidade do <i>S</i> original - 2a área .....	100
Figura 71	Variabilidade do <i>S</i> simulado - 2a área .....	100
Figura 72	Variabilidade do <i>Ph</i> original - 3a área .....	101
Figura 73	Variabilidade do <i>Ph</i> simulado - 3a área .....	102
Figura 74	Variabilidade do <i>K</i> original - 3a área.....	102
Figura 75	Variabilidade do <i>K</i> simulado - 3a área.....	103
Figura 76	Variabilidade do <i>MO</i> original - 3a área .....	103
Figura 77	Variabilidade do <i>MO</i> simulado - 3a área .....	104
Figura 78	Variabilidade do <i>S</i> original - 3a área .....	105
Figura 79	Variabilidade do <i>S</i> simulado - 3a área .....	105

## LISTA DE TABELAS

Tabela 1	Vantagens e desvantagens da simulação .....	19
Tabela 2	Comparação dos modelos cognitivos da IA x redes neurais.....	30
Tabela 3	Erros absolutos sumarizados durante o treinamento na área 1.....	54
Tabela 4	Erros absolutos sumarizados durante o treinamento na área 2.....	57
Tabela 5	Erros absolutos sumarizados durante o treinamento na área 3.....	60
Tabela 6	Porcentagem de amostras simuladas fora do intervalo estabelecido.....	62
Tabela 7	Erros quadráticos médios.....	63

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	14
<b>2</b>	<b>REFERENCIAL TEÓRICO</b> .....	17
<b>2.1</b>	<b>Simulação de sistemas</b> .....	17
<b>2.2</b>	<b>Redes neurais artificiais</b> .....	21
<b>2.2.1</b>	<b>Processos de Aprendizagem</b> .....	23
<b>2.2.2</b>	<b>Paradigmas de aprendizagem</b> .....	25
<b>2.2.3</b>	<b>Arquitetura</b> .....	26
<b>2.3</b>	<b>Inteligência artificial e redes neurais</b> .....	29
<b>2.3.1</b>	<b>Lógica <i>Fuzzy</i></b> .....	31
<b>2.3.2</b>	<b>Sistemas neuro-<i>fuzzy</i></b> .....	31
<b>2.4</b>	<b>Pesquisas para recuperação de áreas degradadas</b> .....	33
<b>2.4.1</b>	<b>Reabilitação de áreas degradadas</b> .....	33
<b>2.5</b>	<b>Simulação de Sistemas Neuro-<i>Fuzzy</i> Adaptativos</b> .....	38
<b>3</b>	<b>MATERIAIS E MÉTODOS</b> .....	40
<b>3.1</b>	<b>O Software Reabilite</b> .....	40
<b>3.1.1</b>	<b>Regra de negócios</b> .....	41
<b>3.1.2</b>	<b>Plataforma de desenvolvimento</b> .....	42
<b>3.2</b>	<b>Sistema neuro-<i>fuzzy</i></b> .....	45
<b>3.2.1</b>	<b>Treinamento</b> .....	49
<b>3.2.2</b>	<b>Simulação</b> .....	50
<b>4</b>	<b>RESULTADOS E DISCUSSÃO</b> .....	51
<b>4.1</b>	<b>Primeira Simulação</b> .....	51
<b>4.2</b>	<b>Segunda Simulação</b> .....	55
<b>4.3</b>	<b>Terceira Simulação</b> .....	58
<b>4.4</b>	<b>Análise de Resultados</b> .....	61
<b>4.5</b>	<b>Resultados Primeira Simulação</b> .....	63
<b>4.6</b>	<b>Resultados Segunda Simulação</b> .....	91
<b>4.7</b>	<b>Resultados Terceira Simulação</b> .....	101
<b>4.8</b>	<b>Análise comparativa</b> .....	105
<b>5</b>	<b>CONCLUSÃO</b> .....	107

<b>REFERÊNCIAS</b> .....	108
--------------------------	-----

## 1 INTRODUÇÃO

Desde os primórdios, o homem vem utilizando a natureza de forma inadequada, o que faz com que haja transformações indesejadas no ecossistema. O solo sofre bastante com tais ações, tornando-o degradado e, na maioria das vezes, infértil. Existem diversos tipos de degradação que são geradas de acordo com o tipo de exploração realizada e que deixa o solo inadequado à utilização ou exposto a processos de degradação contínua, como, por exemplo, mineração, plantio, pastagens, etc. O surgimento das áreas degradadas é bastante preocupante, uma vez que acarreta a poluição dos rios e o desaparecimento da flora e da fauna do local, comprometendo a camada fértil do solo. Todos estes problemas causam grandes danos à natureza e ao homem, impossibilitando a utilização dos recursos naturais e, muitas vezes, impedindo o desenvolvimento sócio econômico do local.

O conceito de desenvolvimento sustentável vem justamente mediar a utilização dos recursos naturais e a preservação das espécies e de habitats naturais, satisfazendo às necessidades da geração atual, sem comprometer as capacidades das gerações futuras. A realização de intervenção positiva nos solos degradados, por meio do estudo sistematizado e criterioso da área, pode ser fundamental para acelerar o processo de regeneração natural do ambiente. Diante desta situação, observa-se a oportunidade de construir uma ferramenta que auxilie na tomada de decisões para o processo de reabilitação do solo e torne

possível simular intervenções positivas na sua fertilidade e que auxilie no processo de restauração natural da floresta.

Este estudo é uma iniciativa para o desenvolvimento de um *software* que auxilie as pesquisas para acelerar o processo de recuperação de solos degradados, por meio de simulações inerentes a tais atividades. Esta ferramenta já disponibiliza os requisitos funcionais necessários para a primeira funcionalidade de simulação, que são cadastro de áreas, que possibilita o gerenciamento de diferentes locais degradados; cadastro de tipos de análises de solos; cadastro de coordenadas e amostras de solos. Portanto, este *software* constitui-se de um kit de funcionalidades para dar suporte a tal processo e o primeiro item criado é um sistema neuro-*fuzzy* (SNF) que simula a fertilidade do solo, o qual é o foco deste trabalho.

O processo de amostragem da área a ser analisada é realizado por meio de coletas de amostras de solo, as quais são enviadas para análise em laboratório. Tal processo pode ser bastante dispendioso para mapeamento de áreas que necessitam de grandes números de amostras, por serem extensas e, em áreas degradadas por processos de mineração, existem dificuldades de acesso e de extração de material rochoso. Em meio a tais dificuldades, encontrou-se a motivação necessária para o desenvolvimento de um modelo para simulação de atributos de solos com um número reduzido de amostras coletadas.

O sistema neuro-*fuzzy* simula atributos do solo em coordenadas geográficas nas quais não foram coletadas amostras para análise. Tal simulação

é baseada nos dados de amostras que foram coletadas e analisadas em laboratório.

O objetivo principal foi criar um sistema de simulação, o qual irá produzir resultados relevantes, proporcionando maior segurança nas decisões de intervenções para a correção da fertilidade do solo, reduzindo custos e aumentando a probabilidade de sucesso nas intervenções. Esta rede utiliza os conceitos de inteligência artificial para aprender a variabilidade dos valores de cada atributo analisado em relação à fertilidade do solo, contém regras de inferência *fuzzy* e provê, como saída, os valores de fertilidade das amostras georreferenciadas simuladas.

## **2 REFERENCIAL TEÓRICO**

Neste capítulo descrevem-se os principais conceitos de simulação de sistemas, redes neurais e lógica *fuzzy* utilizados para o desenvolvimento deste trabalho. Em seguida, apresenta-se uma revisão bibliográfica dos trabalhos atuais na área de reabilitação de áreas degradadas e a simulação neuro-*fuzzy* é apresentada.

### **2.1 Simulação de sistemas**

A simulação implica na modelagem de um processo ou sistema, de tal forma que o modelo imite as respostas do sistema real numa sucessão de eventos que ocorrem ao longo do tempo. Um modelo computacional é um programa de computador cujas variáveis apresentam o mesmo comportamento dinâmico e estocástico do sistema real que representa. Entretanto, a simulação é o processo de projetar um modelo computacional de um sistema real e conduzir experimentos com este modelo, com o propósito de entender seu comportamento e/ou avaliar estratégias para a sua operação (FREITAS, 2008).

Também é definida como uma gama variada de métodos e aplicações que reproduzem o comportamento de sistemas reais, usualmente utilizando-se ferramentas computacionais. Os princípios básicos são criar modelos do sistema

para o qual será construída a simulação, escrever programas destes modelos, utilizar um computador para inicializar o comportamento do sistema e submetê-lo a diversas políticas operacionais (CHWIF; MEDINA, 2010).

Um sistema é um agrupamento de partes que operam juntas, visando um objetivo comum. Um modelo pode ser definido como uma representação das relações dos componentes de um sistema, sendo considerada uma abstração, no sentido em que tende a se aproximar do verdadeiro comportamento do sistema. Existem algumas técnicas de "simulação computacional", tais como estática ou de Monte Carlo, em que o tempo é irrelevante, além de simulação de sistemas contínuos e simulação de eventos discretos. A simulação de eventos discretos se dá, basicamente, por meio de sistemas dinâmicos, nos quais os estados se alteram com o tempo; de sistemas discretos, em que os atributos dos estados só mudam no tempo discreto e da simulação determinística ou estocástica. A simulação pode ser realizada para atingir diversos objetivos, tais como analisar um novo sistema antes de sua implantação, melhorar a operação de um sistema já existente, compreender melhor o funcionamento de um sistema, confrontar resultados e medir eficiências (CHWIF; MEDINA, 2010).

Com a técnica de simulação de eventos discretos torna-se possível visualizar, em computadores, o comportamento do sistema desejado, bem como inserir entradas e analisar como o sistema reage a tais estímulos (BETIATTO, 2013).

Existem alguns *softwares* para simulação de eventos discretos, como por exemplo, o Arena e o ProModel. Tais softwares utilizam pacotes computacionais

de natureza genérica, porém, com características especiais para determinados tipos de aplicações em simulação (SAKURADA; MIYAKE, 2003).

Apesar de a simulação ser uma excelente ferramenta de análise, é preciso conhecer também as vantagens e as desvantagens de seu emprego, os quais estão descritos na tabela 1.

Tabela 1 Vantagens e desvantagens da simulação

<b>Vantagens</b>	<b>Desvantagens</b>
Reusabilidade dos modelos.	A construção de modelos requer treinamento especial.
Passível de uso mesmo que os dados de entrada estejam, ainda, na forma de "esquemas" ou rascunhos.	Envolve arte e o aprendizado se dá ao longo do tempo com a aquisição de experiência.
Pelo alto nível de detalhamento o modelo pode substituir o sistema real.	Os resultados da simulação são, muitas vezes de difícil interpretação.
Compreende-se melhor quais variáveis são as mais importantes em relação à performance e como as mesmas interagem entre si e com outros elementos do sistema.	A modelagem e a experimentação associadas a modelos de simulação consomem muitos recursos, principalmente tempo.
O tempo pode ser controlado, permitindo a reprodução de fenômenos de maneira lenta ou acelerada.	
Facilita a identificação de "gargalos".	
Novas situações sobre as quais se tenha pouco conhecimento e experiência, pode ser tratada de tal forma que tenha, teoricamente, alguma preparação diante de futuros eventos.	

Embora apresente inúmeras vantagens, o processo de simular apresenta algumas dificuldades que evidenciam a necessidade de conhecer bem o problema a ser solucionado. A realização de análises críticas e de estudo criterioso do ambiente a ser simulado permite uma tomada de decisão sensata e acertada ao inicializar um projeto de modelagem e simulação de sistemas (FREITAS, 2008).

A simulação permite ao analista realizar estudos sobre os sistemas modelados para responder a questões do tipo: "o que aconteceria se (...)?", podendo tais estudos ser realizados sobre sistemas que ainda não existem, levando ao desenvolvimento de projetos eficientes, antes que qualquer mudança física tenha sido iniciada. As razões mais comuns para experimentar-se com modelos simulados são: o sistema real ainda não existe: pode ser utilizado para planejar o futuro sistema, e experimentar com o sistema real é dispendioso ou não é apropriado: poderá indicar, com muito menos custo, quais os benefícios de se investir no sistema real. Os passos para a formulação de um estudo para o planejamento e modelagem da simulação podem ser observados na Figura 1 (FREITAS, 2008).

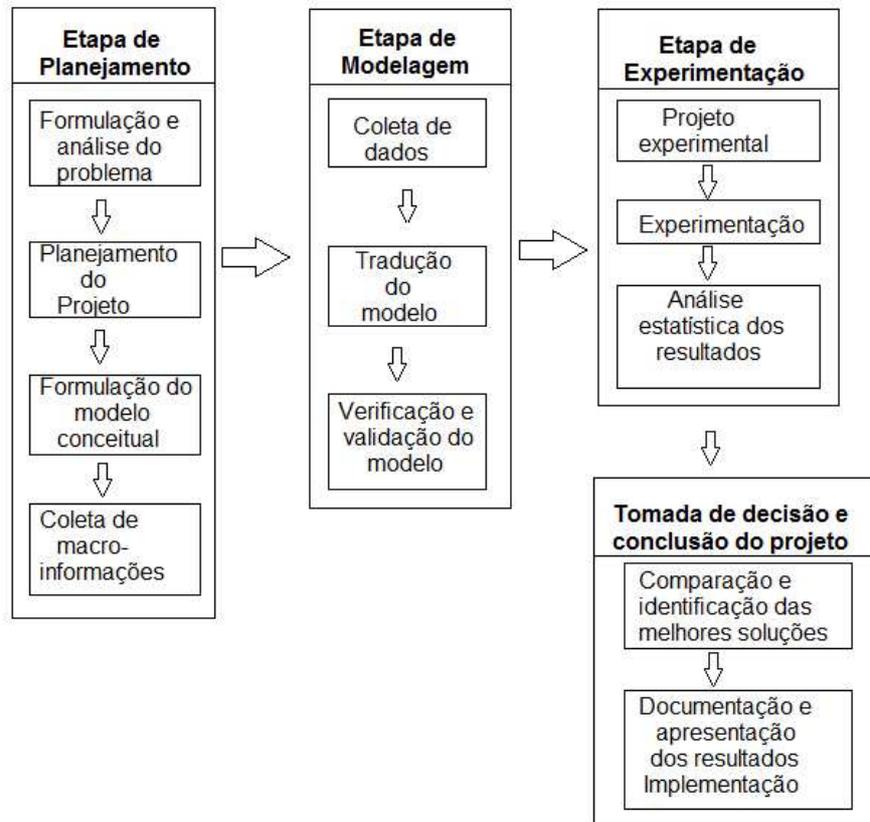


Figura 1 Passos em um estudo envolvendo a modelagem e simulação (FREITAS, 2008)

## 2.2 Redes neurais artificiais

Uma metodologia bastante utilizada em simulação de sistemas são as Redes Neurais Artificiais, ou RNAs. É possível criar *software* de simulação de sistemas utilizando o reconhecimento de padrões, modelos matemáticos, estatística e probabilidade (BISHOP, 2008).

Uma rede neural artificial é uma técnica inspirada no funcionamento do cérebro humano, em que neurônios artificiais, conectados em rede, são capazes de aprender e de generalizar (HAYKIN, 2001).

As RNAs são sistemas paralelos distribuídos, compostos por neurônios artificiais que calculam determinadas funções matemáticas (BRAGA; CARVALHO; LUDERMIR, 2007). Tais neurônios são dispostos em uma ou mais camadas interligadas por um grande número de conexões. Uma rede neural artificial é formada pela interconexão de várias unidades de processamento chamada neurônio, a qual possui características similares à do comportamento humano, como aprendizado, associação e generalização. Segundo Freiman e Pamplona (2005), a teoria da RNA pode ser dividida em três itens fundamentais, os quais são descritos a seguir.

- a) Neurônio artificial: inspirado no neurônio biológico, em três partes, como ilustrado na Figura 2:

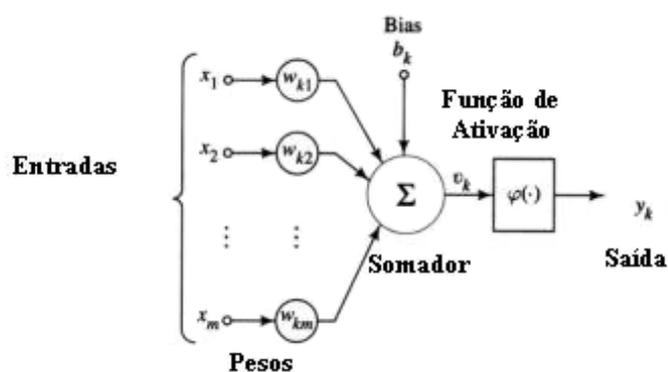


Figura 2 Modelo não linear de um neurônio artificial

- a) Pesos sinápticos que ponderam os valores das entradas do neurônio.
  - b) Regra de propagação que define como as entradas serão combinadas no neurônio - em geral é um somatório ponderado.
  - c) Função de ativação que determina o efeito que o resultado da regra de propagação terá sobre o nível de ativação do neurônio.
- b) Topologia: indica a arquitetura da rede, a quantidade de camadas de entrada, saída, camadas escondidas e fluxo de dados.
- c) Aprendizado: é o processo submetido para treinamento da rede por meio dos dados apresentados. Tal treinamento pode ser supervisionado quando se tem um alvo a ser atingido ou não supervisionado, no qual a rede agrupa valores de maior semelhança.

### **2.2.1 Processos de Aprendizagem**

Haykin (2001) adaptou a definição do processo de aprendizagem de Mendel e McClaren, do ponto de vista de redes neurais, definindo-o como um processo pelo qual os parâmetros livres de uma rede neural são adaptados, por meio de um processo de estimulação pelo ambiente, no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira pela qual a modificação dos parâmetros ocorre. O algoritmo de aprendizagem é um conjunto preestabelecido de regras bem definidas para a solução de um problema, existindo cinco regras básicas de aprendizagem, as quais serão detalhadas a seguir. Não há um

algoritmo de aprendizagem único para um projeto de redes neurais. Entretanto, a escolha do algoritmo de aprendizagem depende diretamente da maneira pela qual uma rede neural se relaciona com o seu ambiente (HAYKIN, 2001).

- a) Aprendizagem por correção de erro: o sinal de erro aciona um mecanismo de controle cujo propósito é aplicar uma sequência de ajustes corretivos aos pesos do neurônio. Tais ajustes são projetados para aproximar, passo a passo, o sinal de saída da resposta desejada. Resulta na regra delta dada por:

$$\Delta w_{kj}(n) = \eta \delta_k(n) x_j(n)$$

- b) Aprendizagem baseada em memória: as experiências passadas são armazenadas explicitamente em memória. É um classificador de padrões que utiliza a regra do vizinho mais próximo.
- c) Aprendizagem hebbiana: base de aprendizagem associativa que resulta numa modificação permanente do padrão de atividade de um grupo de neurônios. É definido como: se dois neurônios, em ambos os lados de uma conexão, são ativados simultaneamente, então, a força daquela conexão é seletivamente aumentada; o contrário também é verdadeiro.
- d) Aprendizagem competitiva: os neurônios de saída de uma rede neural competem entre si para se tornarem ativos e somente um

neurônio de saída pode estar ativo em determinado instante. É muito utilizado para classificar um conjunto de padrões de entrada.

- e) Aprendizagem de Boltzmann: é um algoritmo de aprendizagem estocástico derivado de ideias enraizadas na mecânica estatística. Os neurônios constituem uma estrutura recorrente e operam de maneira binária, uma vez que podem assumir apenas dois tipos de valor, como, por exemplo, ligado ou desligado.

### **2.2.2 Paradigmas de aprendizagem**

A aprendizagem supervisionada é uma forma de aprendizagem que se caracteriza por um professor que tem o conhecimento sobre o ambiente. Tal conhecimento é representado por um conjunto de exemplos de entrada-saída. Entretanto, a rede neural não conhece o ambiente; o professor é quem indica qual é a saída desejada (HAYKIN, 2001).

Aprendizagem não supervisionada é o paradigma no qual o ambiente é totalmente desconhecido, não há um professor e pode ser identificado de duas formas, que são:

- a) aprendizagem por reforço/programação neurodinâmica: o aprendizado de um mapeamento é realizado por meio da interação contínua com o ambiente, visando minimizar um índice escalar de desempenho. Esse tipo de aprendizagem fornece a base para o

sistema interagir como o seu ambiente, desenvolvendo, com isso, a habilidade de aprender a realizar uma tarefa predeterminada, com base apenas nos resultados de sua experiência, que resultam da interação;

- b) aprendizado não supervisionado: são dadas condições para realizar uma medida independente da tarefa da qualidade da representação que a rede deve aprender e os parâmetros livre da rede são otimizados em relação a esta medida.

### **2.2.3 Arquitetura**

A maneira pela qual os neurônios de uma rede neural estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede (HAYKIN, 2001). As arquiteturas (estruturas) de rede, em geral, podem ser identificadas em três classes distintas, que são:

- a) redes alimentadas adiante com camada única: a designação "camada única" se refere à camada de saída de nós computacionais (neurônios), como ilustrado na Figura 3.

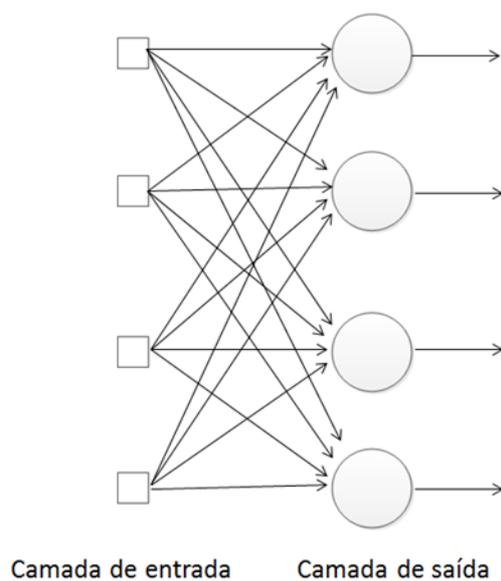


Figura 3 Redes alimentadas adiante com camada única

- b) Redes alimentadas diretamente com múltiplas camadas: esta classe se distingue da anterior pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados correspondentemente de neurônios ocultos, como ilustrado na Figura 4. A função dos neurônios ocultos é intervir entre a entrada externa e a saída da rede de maneira útil, tornando a rede capaz de extrair estatísticas de ordem elevada.

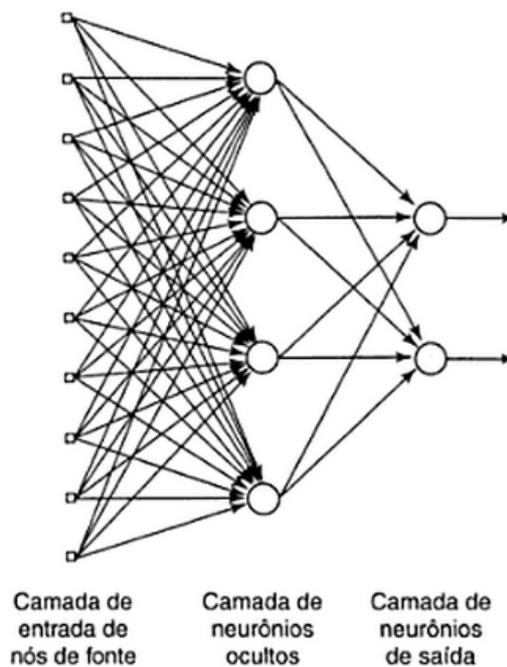


Figura 4 Redes alimentadas diretamente com múltiplas camadas

- c) Redes recorrentes: possuem pelo menos um laço de realimentação e podem consistir, por exemplo, de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios, como se observa na Figura 5.

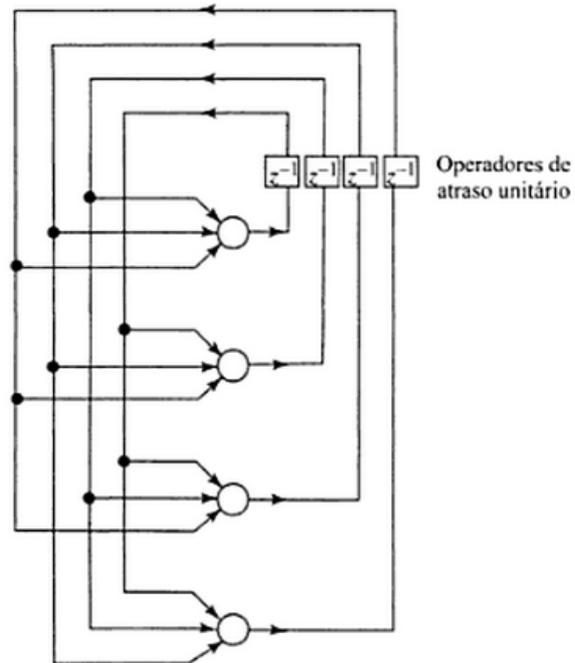


Figura 5 Rede recorrente com neurônios ocultos

### 2.3 Inteligência artificial e redes neurais

O objetivo da Inteligência Artificial (IA) é o desenvolvimento de algoritmos para realizar tarefas cognitivas, executadas por máquinas (HAYKIN, 2001). Um sistema de IA deve ser capaz de fazer três coisas:

- a) armazenar conhecimento, por meio da representação;
- b) aplicar o conhecimento armazenado para resolver problemas, capacidade de raciocínio;
- c) adquirir novo conhecimento através da experiência, aprendizagem.

Inteligência artificial é uma disciplina que estuda como as pessoas resolvem problemas e como as máquinas podem emular este comportamento humano de "solução de problemas" (SIMOES; SHAW, 2007). Em outras palavras, é como fazer com que as máquinas sejam mais atribuídas de características da inteligência humana. De acordo com Haykin (2001), os modelos cognitivos da IA em paralelo com as redes neurais podem ser subdivididos em três itens detalhados na tabela 2:

Tabela 2 Comparação dos modelos cognitivos da IA x redes neurais

	<b>IA</b>	<b>Redes Neurais</b>
<b>Nível de explicação</b>	Representações simbólicas	Modelos de processamento paralelamente distribuído
<b>Estilo de processamento</b>	Sequencial	Paralelismo
<b>Estrutura representativa</b>	Estrutura quase linguística	Natureza e estrutura das representações problemáticas

A IA simbólica pode ser descrita como a manipulação formal de uma linguagem de algoritmos e representações de dados de cima para baixo (*top-down*) (HAYKIN, 2001). Por outro lado, as redes neurais podem ser descritas como processadores distribuídos paralelamente, com uma habilidade natural para aprender, e que, normalmente, operam de baixo para cima (*bottom-up*). Haykin (2001) evidencia que para implementação de tarefas cognitivas, uma

abordagem potencialmente mais vantajosa é construir modelos conexionistas estruturados ou sistemas híbridos que integrem IA simbólica e redes neurais.

### **2.3.1 Lógica *Fuzzy***

Uma técnica que pode integrar uma rede neural, formando um sistema inteligente híbrido, de acordo com Simões e Shaw (2007), é a lógica *fuzzy*, também chamada de difusa ou nebulosa, que incorpora a forma humana de pensar num sistema de controle, como, por exemplo, o raciocínio dedutivo utilizado para inferir conclusões baseadas em informações já conhecidas e, também, o raciocínio indutivo, proveniente da observação do comportamento do processo numa situação dinâmica, ou variante no tempo. Diferentemente da lógica booleana, que tem os estados verdadeiro ou falso, a lógica *fuzzy* trata de valores verdade que variam continuamente de 0 a 1 (SILVA, 2005). Dessa forma, um fato pode ser meio verdade 0,5, quase verdade 0,9 ou quase falso 0,1, permitindo expressar o conhecimento num formato de regra que é bastante parecido com a linguagem natural.

### **2.3.2 Sistemas neuro-*fuzzy***

A lógica *fuzzy* providencia os fundamentos teóricos para a captura de incertezas associadas aos processos do pensamento humano (SIMÕES; SHAW, 2007). Entretanto, um sistema neuro-*fuzzy* combina técnicas de redes neurais e

inferências *fuzzy*, respectivamente associando a capacidade de aprendizagem e interpretação, permitindo a integração de conhecimentos implícitos - conjunto de dados de treinamento e explícitos - provenientes de experts. De acordo com Ferreira (2009), a utilização de neurônios lógicos *fuzzy* permite o processamento de conhecimento implícitos e explícitos, para a solução de problemas das mais variadas formas.

Um sistema neuro-*fuzzy* permite que o conhecimento seja extraído com base em regras de inferência *fuzzy*, por meio da integração do conhecimento explícito e implícito. A arquitetura de um sistema neuro-*fuzzy*, com  $p$  entradas,  $m$  neurônios, suas funções de validação  $\Phi_m$ , resultados  $y_m$  e saída  $Y$  está ilustrada na Figura 6.

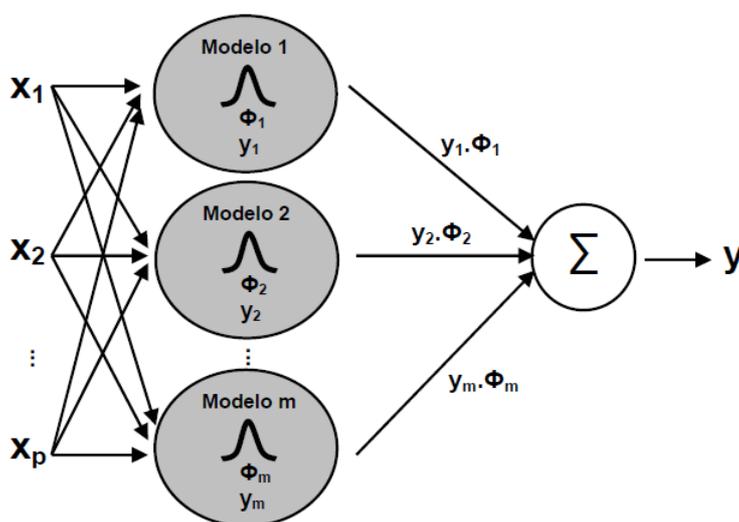


Figura 6 Arquitetura neuro-*fuzzy*

## **2.4 Pesquisas para recuperação de áreas degradadas**

A presente seção apresenta uma breve revisão bibliográfica de trabalhos relacionados à reabilitação de áreas degradadas.

### **2.4.1 Reabilitação de áreas degradadas**

As áreas de meio ambiente e ciências agrárias têm uma subárea denominada "silvicultura". A silvicultura é uma arte de planificação a longo prazo, com base em informação detalhada sobre as características da floresta, com vista a alcançar o estado desejado (ALVES; SILVA NETO, 2011). Em uma definição informal, é uma ciência dedicada ao estudo dos métodos naturais e artificiais de regenerar e melhorar os povoamentos florestais, com o objetivo de satisfazer às necessidades do mercado e, ao mesmo tempo, aplicar esse estudo para a manutenção, o aproveitamento e o uso racional das florestas. Dessa forma, auxilia na recuperação de florestas e amplia as possibilidades de manutenção dos biomas locais, por meio do plantio de mudas, possibilitando a recuperação dos recursos hídricos e da biodiversidade. Os tratamentos silviculturais são intervenções florestais destinadas a manter ou melhorar o valor da floresta (RIBEIRO et al., 2002).

Na América do Sul, existem 244.106 ha de solo degradado, dos quais 41% são devido ao desmatamento; 27,9% ao superpastejo; 26,2% a atividades agrícolas e 4,9% à exploração intensa da vegetação. No Brasil, embora não haja

dados exatos, apontam-se o desmatamento e as atividades agrícolas como principais fatores de degradação (ABDO, 2013).

As ações de restauração estão, cada vez mais, sendo implementadas em todo o mundo, apoiadas por compromissos políticos. Um dos principais objetivos da restauração ecológica é o restabelecimento das características do ecossistema como a biodiversidade e as funções ecológicas que existiam antes da degradação (BENAYAS et al., 2009).

A recuperação do solo e da biodiversidade feita apenas pela natureza é um processo muito lento e pode durar anos e até séculos. Entretanto, esse tempo pode ser reduzido com um processo de identificação e intervenção artificial, que é a essência da restauração ecológica. Em uma área degradada, é no solo é onde se encontram os maiores problemas, tais como metais pesados, *pH*, salinidade de compostos orgânicos, toxicidade, textura, estrutura, estabilidade da umidade, macronutrientes e micronutrientes. Para cada tipo de problema existe tratamento imediato e em longo prazo, como, por exemplo, um solo de textura grosseira, o tratamento imediato seria adicionar matéria orgânica e, em longo prazo, fazer o plantio de vegetação (DOBSON; BRADSHAW; BAKER, 1997).

A restauração da fertilidade do solo pode ser pré-requisito para a recuperação florestal em lugares severamente degradados. Nestes casos, o auxílio humano é imprescindível para recuperar a estrutura da floresta, a composição e a interação de espécies.

Existem algumas métricas para medir o nível de recuperação da floresta. Muitos estudos focam nas medidas estruturais, como área basal, biomassa acima

do solo, altura das árvores ou densidade do caule. Outros examinam mudanças na estrutura dorsal, frequência e tamanho das lacunas nas copas e a disponibilidade de luz durante a recuperação. Nutrientes do solo e estoques de carbono também podem ser utilizados como medidas de recuperação das funções do ecossistema (CHAZDON, 2003).

Nos estudos sobre cobertura contínua de florestas, uma forma para reflorestar áreas devastadas é denominada nurse crops. Este é um método de plantio de espécies que facilitam o crescimento da espécie desejada. Os principais componentes do CCF são: continuidade das condições da floresta, ênfase na estrutura horizontal e vertical da árvore, mistura de espécies de idades diferentes, atenção a limitações do solo, seleção individual das árvores, conservação de árvores antigas, preferências por espécies nativas e folhosas em particular, proteção florestal e manejo da fauna silvestre ecologicamente correto (POMMERENING; MURPHY, 2004).

É extremamente importante conciliar o reflorestamento com o combate à pobreza rural. Muito se discute a respeito de reabilitar áreas para o manejo de florestas comerciais, mas existe pouca preocupação com as comunidades pobres que vivem em torno de tais florestas. É preciso pensar no reflorestamento sustentável, que pode gerar emprego e recuperar a biodiversidade das florestas. Uma forma de aumentar a cobertura florestal é proteger e gerir grandes áreas de florestas. Nem toda área degradada está completamente desmatada; é necessário apenas criar planos de recuperação adequados a cada tipo e nível de degradação (LAMB; ERSKINE; PARROTTA, 2005).

É necessário tomar muito cuidado ao tentar restaurar uma área degradada, sendo necessário o conhecimento a fundo do solo e do clima do local. Dependendo da degradação do solo, esforços de restauração intensiva podem retardar a recuperação do ecossistema. Num local com distúrbios no solo e na vegetação, o plantio direto de mudas de árvores pode reduzir a densidade da regeneração natural e, com isso, fazer com que a recuperação da área seja lenta (SAMPAIO; HOLLAND; SCARIOT, 2007).

Para Anderson, Howarth e Walker (2007), a restauração e a sucessão ecológica estão intrinsecamente ligadas, pois a sucessão compreende mudança de espécies e substrato ao longo do tempo e a restauração é a manipulação intencional destas mudanças. O estudo da sucessão oferece valiosas lições para a melhoria da qualidade dos programas de restauração. Tais lições sugerem táticas de restauração como, por exemplo, para possibilitar a proteção de espécies desejáveis.

Existem três estratégias diferentes para a criação de novos ecossistemas durante a restauração ecológica. A mais simples é deixar o local sem intervenção; é de baixo custo, mas pode levar décadas, e até mesmo séculos, para se recuperar. Outra estratégia é utilizar uma solução técnica, na qual as variáveis abióticas, bióticas e biológicas podem ser alteradas, controladas por meio da introdução de espécies desejadas. Entre estas duas existe uma abordagem na qual a sucessão espontânea é monitorada por limitação física ou manipulação biológica apenas. A limitação física se dá pela melhoria do local, de forma que permita a colonização no processo de criação do pool de espécies. Na

manipulação biótica, são adicionados alguns biotas artificialmente, podendo aumentar a colonização de espécies não esperadas (PRACH et al., 2007).

A recuperação de solos depende de como ele foi degradado, obtendo-se três categorias. A primeira é a falta de insumos, tais como água, adubos e cultivares. A segunda está relacionada aos excessos de culturas, provocando o desequilíbrio de sais, toxicidade, baixa umidade, baixa de *pH* e pedregosidade. A terceira categoria está relacionada a problemas como erosão acelerada, compactação do solo, drenagem impedida, acidez induzida por adubos, toxicidade devido a lixo tóxico, mineração. Conhecer o processo de degradação do solo é imprescindível para a sua recuperação. Cooper (2008) enfatiza que é necessário estabelecer uma relação de causa e efeito para a aplicação da solução de restauração.

A "sucessão florestal" pode ser um processo de reabilitação de áreas degradadas, sendo um processo estocástico, resultando do comportamento de populações e espécies. É muito importante a realização de pesquisas experimentais para determinar os passos mais eficientes para iniciar um processo de reabilitação por intervenção humana. Os estudos apontam falhas e acertos em determinados processos, indicando o melhor caminho a ser seguido, possibilitando que uma área seja reabilitada em tempo menor e com menor custo (CHAZDON, 2008).

Uma técnica que utiliza fixação de nitrogênio em árvores leguminosas para a recuperação de áreas degradadas por processos de erosão e mineração, enfatiza o potencial desta técnica para recuperar o solo, bem como os níveis de

matéria orgânica e biodiversidade do ecossistema. Esta técnica pode ser utilizada em várias situações, como, por exemplo, em solos degradados por processos de mineração. O sucesso de aplicação da técnica está condicionado à escolha correta de espécies, propágulos, polinizadores e dispersores de sementes, necessários para o avanço da sucessão natural da vegetação. O objetivo é acelerar o processo natural de recuperação do ecossistema (CHAER et al., 2011).

## **2.5 Simulação de Sistemas Neuro-Fuzzy Adaptativos**

Kisi et al. (2009) investigaram a precisão de um modelo de simulação neuro-*fuzzy* adaptativo para estimar o volume da vazão mensal de sedimentos em duas estações hidrológicas. Tal estudo indicou que a técnica obteve sucesso nas estimativas esperadas. Cobaner, Unal e Kisi (2009) utilizaram técnicas de redes neurais e lógica *fuzzy*. O estudo comparativo do modelo neuro-*fuzzy* adaptativo gerou melhores resultados do que em redes *Multi Layer Perceptron* (MLP) e Rede de Base Radial (RBF). Neste estudo, foi utilizado um modelo híbrido de *perceptrons* e conjunto de inferências *fuzzy*. Entretanto, Cobaner, Unal e Kisi (2009) concluíram que o modelo pode ser integrado a modelos gerais hídricos, para potencializar os estudos de modelagem hídrica. Rajaei et al. (2009) também utilizaram um modelo neuro-*fuzzy* para simular a vazão diária de sedimentos em estações hidrológicas e obtiveram resultados satisfatórios e melhores que os modelos implementados somente com uma técnica isolada.

Akrami, El-Shafie e Jaafar (2013) utilizaram a mesma técnica que Cobaner, Unal e Kisi (2009), a modelagem *neuro-fuzzy*, para medir a pluviosidade e obtiveram maior precisão na previsão da precipitação, pois ela fornece convergência mais rápida e menor complexidade computacional, mantendo desempenho excelente de dois modelos típicos *neuro-fuzzy*, em comparação com o modelos convencionais. Dutta e Terhorst (2013) analisaram técnicas para estimativas de umidade do solo por meio de ferramentas de aprendizado supervisionado. Dentre os modelos testados, o melhor resultado obtido foi no sistema *neuro-fuzzy*, que conseguiu prever 92% dos pontos na área total estimada.

### **3 MATERIAIS E MÉTODOS**

Neste trabalho, primeiramente, foi realizado uma busca por ferramentas de software para auxílio em estudos de recuperação de áreas degradadas. Foi desenvolvido um sistema de simulação neuro-*fuzzy* para receber como entrada os dados de amostras analisadas em laboratório, podendo cada amostra analisada apresentar até 18 atributos. Foi criada uma regra de inferência que relaciona o atributo altitude, com a finalidade de se obter a relação entre o valor do atributo da amostra e a altitude do ponto onde foi coletada. A saída do sistema neuro-*fuzzy* são amostras simuladas em pontos georreferenciados diferentes das amostras originais.

#### **3.1 O Software Reabilite**

Foi desenvolvido um *software* de auxílio aos estudos e processos de recuperação de áreas degradadas. Reabilite é uma ferramenta web e tem como principal objetivo subsidiar a tomada de decisões em pesquisas de reabilitação de solos em diferentes locais do globo terrestre. O *software* foi criado para suportar a inserção de novas funcionalidades, de acordo com a demanda de necessidades.

### 3.1.1 Regra de negócios

A ferramenta foi criada para cadastrar usuários e locais físicos tidos como objetos de pesquisa para restauração ecológica e/ou mapeamento de propriedades físico-químicas. Um usuário pode trabalhar com vários locais. Um local é denominado área reabilite e para cada área devem ser inseridos os dados de entrada, como ilustrado na Figura 7. A primeira funcionalidade criada foi a simulação de atributos ou propriedades do solo, a qual é detalhada na próxima sessão.

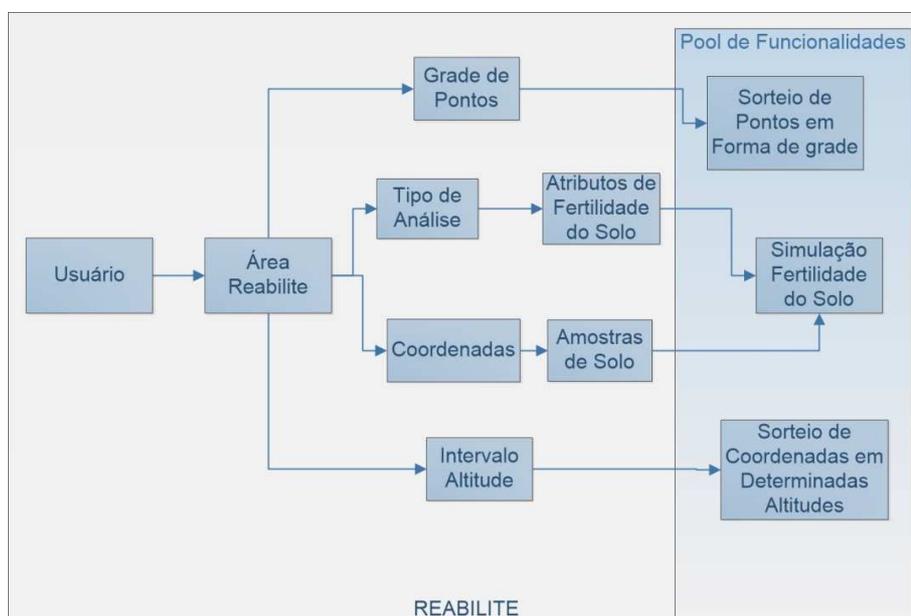


Figura 7 Fluxo de procedimentos reabilite

### 3.1.2 Plataforma de desenvolvimento

A escolha pela plataforma *web* se deu pelo fato de ela reunir maior número de vantagens em relação a *desktop* e, principalmente, por facilitar uma futura expansão da ferramenta para dispositivos móveis. Dentre as principais vantagens da plataforma *web* podem-se citar:

- a) realização de pesquisas de recuperação de áreas degradadas de locais diversos, acessando e utilizando uma mesma base de dados;
- b) acesso por meio de um navegador qualquer (*web browser*);
- c) mobilidade, acessibilidade: aplicação disponível em qualquer lugar com acesso à internet;
- d) investimento reduzido: baixo custo de instalação e manutenção;
- e) gerenciamento centralizado: é uma única aplicação;
- f) multiplataforma: independente do sistema operacional do usuário.

Para desenvolver o *software*, foram utilizadas as linguagens de programação Java e JSP, ambiente de desenvolvimento NetBeans IDE 7.0 e banco de dados *MySQL*. Partindo dos princípios e conceitos da teoria geral de sistemas, pode-se dizer que o software em questão é um sistema aberto, uma vez que é possível trocar informações entre locais degradados. O sistema utiliza informações de mapas de satélites do *Google maps* e está codificado para receber informações apropriadas para cada tipo de simulação que possa ser

utilizada em funcionalidades futuras. Na Figura 8 está ilustrada a página inicial do sistema Reabilite e, na Figura 9, a arquitetura do banco de dados.



Figura 8 Página inicial do REABILITE

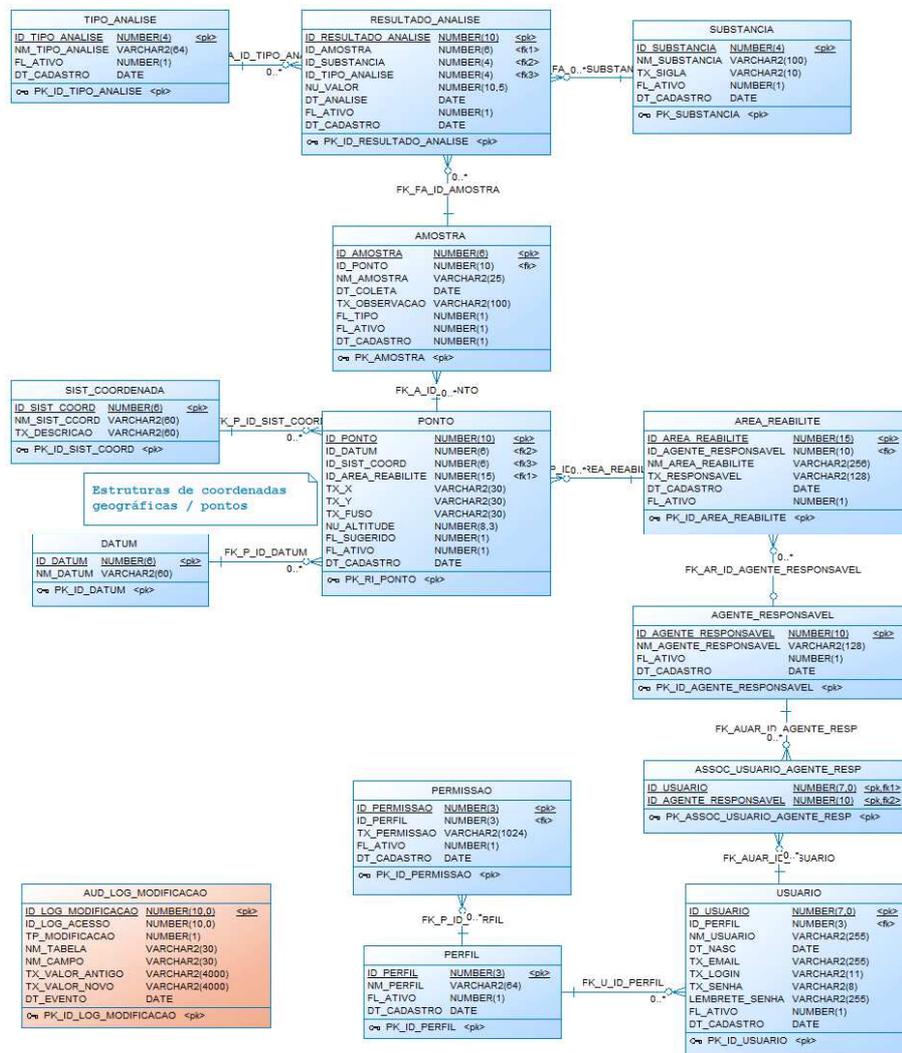


Figura 9 Arquitetura de banco de dados

### 3.2 Sistema neuro-fuzzy

No intuito de mapear as propriedades físico-químicas do solo na área a ser recuperada, foi criado um sistema neuro-fuzzy (SNF), que recebe como entrada amostras de solo e suas respectivas propriedades, bem como os dados de latitude, longitude e altitude. O SNF foi projetado com base na arquitetura de redes neurais MLP, que são compostas por um conjunto de neurônios lineares e um conjunto de inferências fuzzy. A equação 2 descreve a expressão matemática do *perceptron*, executada dentro de cada neurônio, que difere um do outro pelo fato de representarem um atributo específico do solo. Um neurônio caracteriza seu próprio valor de acordo as regras de classificação descritas por Ribeiro e Guimarães (1999).

$$y_k = \sum_{j=1}^m w_{kj}x_j + b_k$$

em que:

K é a coordenada da amostra;

y<sub>K</sub> é a saída do neurônio: valor simulado dos atributos que participam da fertilidade;

Sinais são apresentados à entrada (x<sub>1</sub> à x<sub>m</sub>), que é o valor dos atributos da fertilidade;

Cada sinal é multiplicado por um peso que indica sua influência na saída da unidade (w<sub>K</sub>);

Bias  $b_k$  tem o papel de aumentar ou diminuir a influência do valor das entradas.

Cada saída do neurônio passa por um crivo de regras *fuzzy*, como ilustrado na Figura 10, que relaciona o valor calculado com os valores de dois vizinhos mais próximos e suas respectivas altitudes. Este crivo de regras faz um ajuste nebuloso, o qual verifica se o valor encontrado está de acordo com os valores dos vizinhos e dentro da altitude, somando ou subtraindo, até que esteja dentro da faixa ideal para aquela altitude.



Figura 10 Sistema neuro-*fuzzy*

A seguir se observa a lista de inferências *fuzzy* utilizadas para o ajuste nebuloso.

- a) Calcula a porcentagem da diferença para ajuste, descrita na equação 3:
  - a)  $p_{Di} f = ((\text{altitudeS} - \text{altitudeA}) + (\text{altitudeS} - \text{altitudeB}))/100$
- b) Se a altitude do ponto simulado está entre a altitude dos pontos vizinhos, então executa o cálculo do valor de ajuste descrito na regra 4:

- a) se  $(v_A \geq v_B)$  entao  $\{A \text{ juste} = v_A - (pDif / 2)\}$  senao  $\{A \text{ juste} = v_A + (pDif / 2)\}$
- c) Se a altitude do ponto simulado está acima da altitude dos pontos vizinhos, então executa o cálculo do valor de ajuste descrito na regra 5:
- a) se  $(v_A > v_B)$  entao  $\{A \text{ juste} = v_B + pDif\}$  senao  $\{A \text{ juste} = v_B - pDif\}$
- d) Se a altitude do ponto simulado está abaixo da altitude dos pontos vizinhos, então executa o cálculo do valor de ajuste descrito na regra 6:
- a) se  $(v_A \geq v_B)$  entao  $\{A \text{ juste} = v_A + pDif\}$  senao  $\{A \text{ juste} = v_A - pDif\}$

onde:

- a) altitudeA é a altitude do vizinho A;
- b) altitudeB é a altitude do vizinho B;
- c) altitudeS é a altitude do ponto simulado;
- d) pDif é a porcentagem do quanto o valor simulado está diferente de seus vizinhos;
- e)  $v_A$  é o valor do atributo do vizinho A;
- f)  $v_B$  é o valor do atributo do vizinho B;
- g) Ajuste é o valor a ser ajustado;

A arquitetura do SNF, ilustrada na Figura 11, é composta por dezoito neurônios, que representam os atributos a serem simulados e um neurônio de

inferência *fuzzy*. Para a realização da simulação, o usuário tem a flexibilidade de escolher quais atributos deseja simular. Cada amostra pode apresentar até 18 atributos químicos, dentre os listados a seguir.

pH (pH em água);	SB (soma de bases trocáveis);
P-rem (fósforo remanescente);	t (capacidade de troca catiônica efetiva);
P (fósforo);	T (capacidade de troca catiônica a pH 7,0);
K (potássio);	V (índice de saturação de bases);
Na (sódio);	m (índice de saturação de alumínio);
Ca (cálcio);	MO (matéria orgânica); B (boro);
Mg (magnésio);	S (enxofre);
Al (alumínio);	CE (condutividade eletrolítica).
H + Al (hidrogênio + alumínio);	

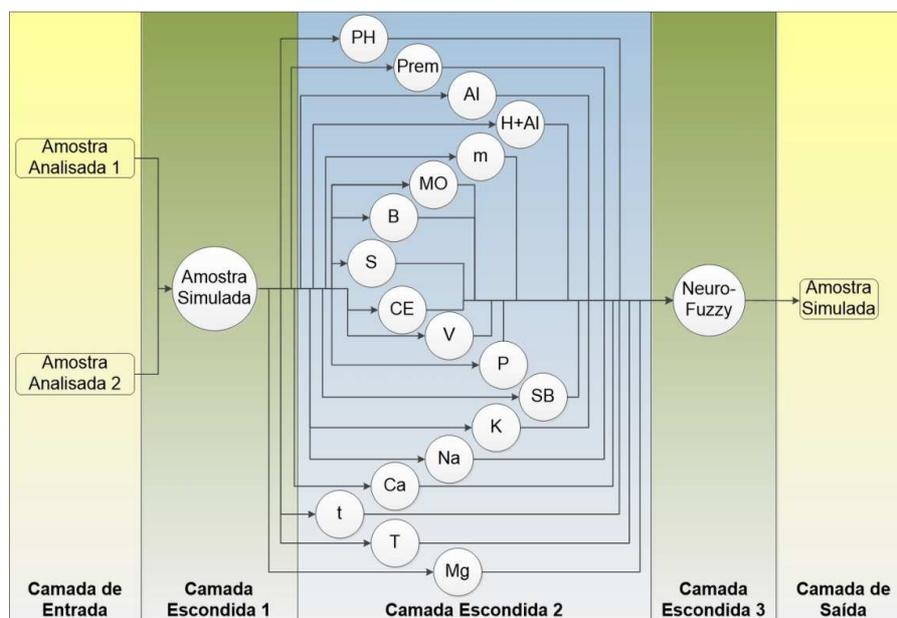


Figura 11 Arquitetura do sistema neuro-*fuzzy*

### 3.2.1 Treinamento

Foi criado um modelo de simulação adaptativo e, assim, é necessário que seja feito um treinamento da rede a cada nova área a ser simulada. Para o treinamento, foram utilizadas amostras de solo, as quais foram coletadas em pontos georreferenciados por latitude e longitude, em que cada atributo foi analisado em laboratório. O número de épocas estabelecido foi igual ao número de amostras para treinamento, para melhor desempenho da simulação. Foi realizado o treinamento supervisionado com a regra de aprendizagem de correção por erro. Os erros de treinamento foram calculados com base nos

valores originais de cada atributo, numa tentativa de obter valores simulados dentro de uma faixa de valor mínimo e máximo.

### 3.2.2 Simulação

O processo de simulação é realizado em três etapas principais, que são: treinamento do sistema neuro-*fuzzy*;

- a) sorteio das coordenadas simuladas: com polígono selecionado pelo usuário, é obtido o ponto central do mesmo.
- b) Os pontos simulados são sorteados em espiral, expandindo o raio do ponto central e rotacionando-os;
- c) apresentação dos dados ao SNF: as amostras originais e os pontos sorteados são apresentados ao SNF que, por sua vez, simula os valores para cada ponto sorteado.

Nos testes com o SNF foram realizadas simulações de amostras georreferenciadas em três áreas, neste documento denominadas área 1, área 2 e área 3, sendo a área degradada por processos de mineração e as áreas 2 e 3, de agricultura de precisão.

## **4 RESULTADOS E DISCUSSÃO**

Neste capítulo descrevem-se os resultados obtidos de três simulações, as quais representam dados de áreas distintas. A primeira simulação foi realizada com dados de uma área degradada por processos de mineração. As outras foram coletadas em áreas de agricultura.

### **4.1 Primeira Simulação**

As amostras de solo foram coletadas no dia 26/02/2011, numa área degradada por processos de mineração, com extensão de 18,2 ha, aqui denominada Área 1. A coleta foi realizada visando representar, da melhor forma possível, a heterogeneidade observada visualmente em locais onde não havia dificuldades para extração do solo, visto que áreas degradadas por processos de mineração apresentam dificuldades de acesso. O SNF tem como entrada as dezesseis amostras de solo originais e dezoito pesos, pois cada atributo/propriedade recebe um peso (resultado do treinamento da rede); latitude, longitude e altitude são os dados utilizados pela inferência fuzzy. Na simulação desta área utilizaram-se todos os neurônios implementados, bem como a inferência de altitude dos pontos que visa encontrar uma relação do valor do atributo com a altitude do local coletado. Na Figura 12 estão ilustrados a área selecionada e os pontos utilizados para treinamento da rede. A simulação gerou 68 amostras georreferenciadas descritas na Figura 13, representadas por pontos

azuis. O ponto vermelho representa o centro do polígono da área e os pontos verdes são as amostras utilizadas no treinamento e na validação da rede.



Figura 12 Delimitação da área 1



Figura 13 Pontos simulados na área 1

Nos primeiros ciclos de treinamento, os erros absolutos foram maiores, os quais diminuíram até a metade do ciclo, exceto para os atributos  $H+Al$ ,  $T$  e  $MO$ , que foram atenuando apenas após decorrida metade do ciclo de treinamento. Ao final, todos os erros se aproximaram de zero. Os erros absolutos de treinamento da área 1 estão descritos na tabela 3, os quais foram sumarizados em 7 faixas.

Tabela 3 Erros absolutos sumarizados durante o treinamento na área 1

<b>Atributo</b>	<b>F 7</b>	<b>F 6</b>	<b>F 5</b>	<b>F 4</b>	<b>F 3</b>	<b>F 2</b>	<b>F 1</b>
<i>Ph</i>	0,066	0,006	0,000	0,000	0,000	0,000	0
<i>P-rem</i>	68,289	0,520	0,479	0,000	0,000	0,000	0
<i>P</i>	0,001	0,000	0,000	0,000	0,000	0,000	0
<i>K</i>	0,001	0,000	0,000	0,000	0,000	0,000	0
<i>Na</i>	0,686	0,545	0,331	0,000	0,000	0,000	0
<i>Ca</i>	0,171	0,000	0,000	0,000	0,000	0,000	0
<i>Mg</i>	0,129	0,000	0,000	0,000	0,000	0,000	0
<i>AL</i>	0,001	0,000	0,000	0,000	0,000	0,000	0
<i>H + Al</i>	28,924	21,643	20,031	0,506	2,923	2,904	0
<i>SB</i>	0,159	0,128	0,000	0,000	0,000	0,000	0
<i>t</i>	0,051	0,033	0,000	0,000	0,000	0,000	0
<i>T</i>	29,182	18,539	14,349	0,900	0,739	0,307	0
<i>V</i>	0,001	0,000	0,000	0,000	0,000	0,000	0
<i>m</i>	14,077	0,128	0,000	0,000	0,000	0,000	0
<i>MO</i>	12,303	0,802	0,691	0,529	0,528	0,102	0
<i>B</i>	0,001	0,000	0,000	0,000	0,000	0,000	0
<i>S</i>	0,001	0,000	0,000	0,000	0,000	0,000	0
<i>CE</i>	0,001	0,000	0,000	0,000	0,000	0,000	0

Na Figura 13 observam-se os resultados obtidos da simulação de todos atributos, comparando-se os dados das amostras originais e simuladas. Ficou claro que os valores simulados acompanham a tendência dos valores originais, com pequenas diferenças em alguns atributos, como *P-rem*, *H+Al* e *T*.

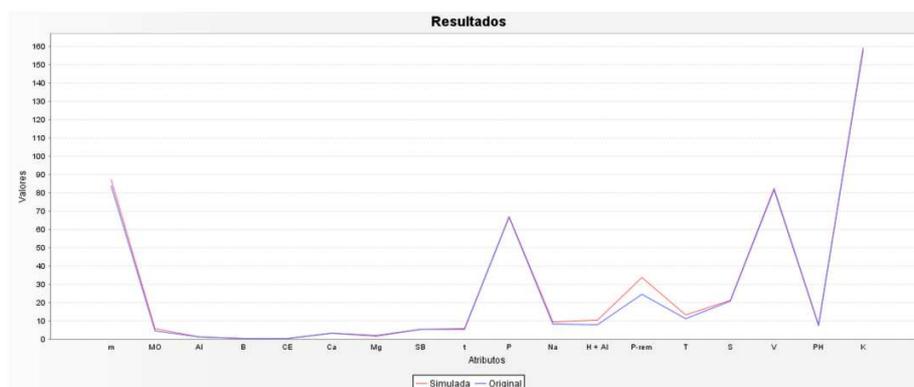


Figura 14 Resultados da 1ª área simulada

## 4.2 Segunda Simulação

Foram utilizadas amostras de solo, da segunda área simulada, cedidas por uma empresa de análises agrícolas e ambientais. Tais amostras foram analisadas para a aplicação de agricultura de precisão, tendo sido extraídas na camada superficial (0-20 cm) e coletadas em 2012. Foram utilizados alguns atributos que caracterizam o solo, tais como *pH*, *K*, *Ca*, *Mg*, *H+Al*, *MO* e *S*. Neste caso, a regra de altitude do ponto não influenciou os resultados, visto que, na área geográfica em que os pontos foram retirados, não existem diferenças de nível do solo. Na Figura 15 estão ilustradas a área selecionada, bem como os pontos georreferenciados das amostras coletadas que foram utilizadas para treinamento e validação da simulação. Foram simuladas 334 amostras georreferenciadas, as quais podem ser observadas na Figura 16, representadas

pelos pontos azuis. Das amostras coletadas e analisadas em laboratório no total de 125 pontos, 63 foram utilizados para treinamento da rede (representados pelos pontos verdes) e 62 (em vermelho) foram usadas para validação.



Figura 15 Delimitação da área 2

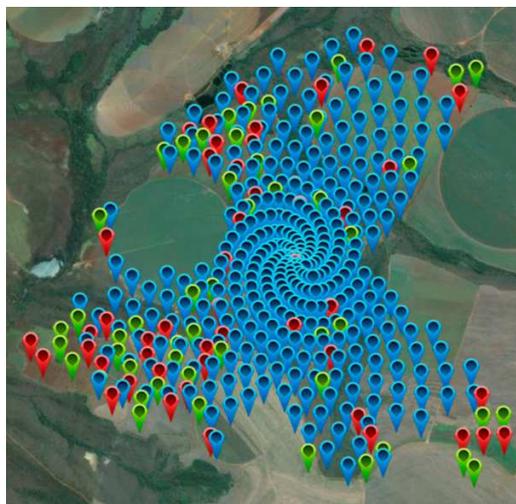


Figura 16 Pontos simulados na área 2

Durante o treinamento, a aprendizagem foi avaliada por meio da análise dos erros de cada atributo. Os erros absolutos variaram bastante até que se estabilizaram tendendo a zero. Os erros absolutos de treinamento podem ser visualizados na tabela 4, os quais foram sumarizados em 5 faixas. Na Figura 15 observam-se os resultados obtidos da simulação dos atributos inseridos como entrada das amostras originais e simuladas. O gráfico descreve que os valores simulados seguem a mesma tendência dos valores originais de validação, mostrando que a rede conseguiu simular os dados de acordo com os valores reais, com margem de erro um pouco maior nos atributos P e S.

Tabela 4 Erros absolutos sumarizados durante o treinamento na área 2

<b>Atributo</b>	<b>F 5</b>	<b>F 4</b>	<b>F 3</b>	<b>F 2</b>	<b>F 1</b>
<b>Ph</b>	0,001	0,000	0,000	0,000	0
	0,001	0,000	0,000	0,000	0

<b>K</b>	0,001	0,000	0,000	0,000	0
<b>Ca</b>	0,377	0,000	0,000	0,000	0
<b>Mg</b>	0,114	0,032	0,028	0,023	0
<b>H+Al</b>	0,909	0,604	0,441	0,000	0
<b>MO</b>	12,043	0,627	0,342	0,000	0
<b>S</b>	0,001	0,000	0,000	0,000	0

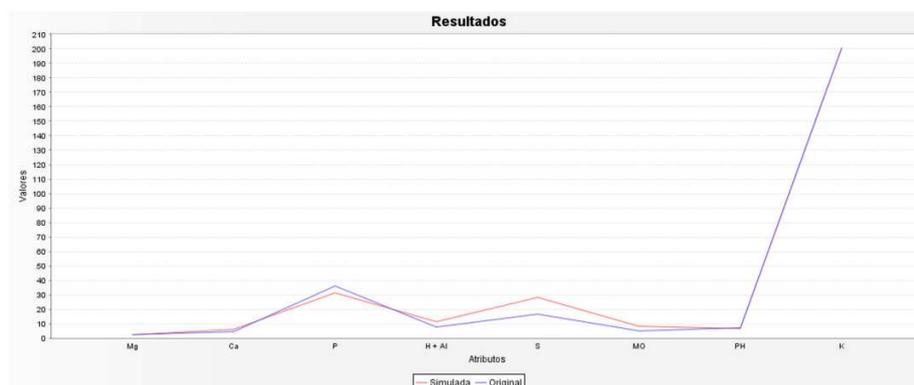


Figura 17 Resultados da 2a área simulada

### 4.3 Terceira Simulação

As amostras de solo foram extraídas na camada superficial (0- 20 cm), utilizando grade regular de 2 ou 3 hectares e 10 subamostras para a obtenção de uma amostra composta, com a finalidade de aplicação da agricultura de precisão no manejo da fertilidade do solo. Alguns atributos que caracterizam o solo, tais como *pH*, *P*, *K*, *MO* e *S*, foram inseridos no simulador. Nesta simulação, a altitude dos pontos também não influenciou nos resultados, pois é uma área plana de agricultura. Na Figura 18, observam-se os pontos georreferenciados das amostras coletadas e analisadas no laboratório, que foram utilizadas para

treinamento e validação da simulação. Foram simuladas 194 amostras georreferenciadas, as quais podem ser observadas na Figura 19, representadas pelos pontos azuis. Das amostras coletadas e analisadas em laboratório, no total 118 de pontos, metade foi utilizada para treinamento da rede (representados pelos pontos verdes) e o restante (em vermelho), para validação.



Figura 18 Delimitação da área 3



Figura 19 Pontos simulados na área 3

No treinamento da rede observou-se que à medida que os ciclos foram se passando, os erros absolutos de treinamento foram diminuindo. Os valores dos erros dos atributos  $pH$ ,  $P$  e  $K$  se comportaram de forma semelhante. Entretanto,  $MO$  e  $S$  tiveram valores maiores e o erro só se estabilizou no final do treinamento. Tais valores estão descritos na tabela 5, tendo sido sumarizados em 7 faixas. Na Figura 20 ilustram-se os resultados obtidos da simulação dos atributos analisados nas amostras originais. Observou-se que os valores das amostras simuladas estão de acordo com os valores originais utilizados exclusivamente para validação, com margem de erro mínima.

Tabela 5 Erros absolutos sumarizados durante o treinamento na área 3

<b>Atributo</b>	<b>F 7</b>	<b>F 6</b>	<b>F 5</b>	<b>F 4</b>	<b>F 3</b>	<b>F 2</b>	<b>F 1</b>
<b>Ph</b>	0,001	0,000	0,000	0,000	0,000	0,000	0
<b>P</b>	0,001	0,000	0,000	0,000	0,000	0,000	0

<b>K</b>	0,001	0,000	0,000	0,000	0,000	0,000	0
<b>MO</b>	0,570	0,470	0,418	0,324	0,102	0,000	0
<b>S</b>	0,570	0,570	0,470	0,418	0,324	0,102	0

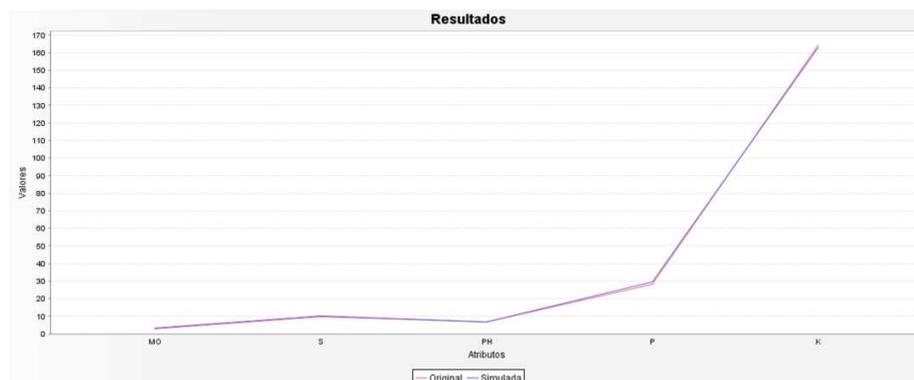


Figura 20 Resultados da 3a área simulada

#### 4.4 Análise de Resultados

A princípio, os ciclos de treinamento foram fixados em 20 épocas, mas os resultados obtidos não correspondiam às metas propostas, nas três simulações. No decorrer dos testes, foi identificado que o número de ciclos ideal supostamente estava relacionado com o número de dados para treinamento. Então, foi implementada esta relação, fixando-se o número de épocas ao número de dados de treinamento. Apenas na primeira simulação o número de épocas foi 20, pelo fato de o número de dados não ter conseguido mapear a variabilidade dos valores dos atributos da área, apenas 16 amostras. Na segunda e na terceira simulação, a relação foi estabelecida, tendo o número de épocas sido igual ao número de dados. Entretanto, a segunda simulação teve 63 amostras de

treinamento e 63 épocas e a terceira simulação, 59 amostras de treinamento e 59 épocas. Os dados simulados nas três áreas correspondem à expectativa da faixa de valores na relação ponto geográfico - valor. Tais valores simulados não estão exatamente dentro da faixa estabelecida dos vizinhos mais próximos, mas a maioria dos atributos está dentro da faixa geral das amostras de validação, como se observa na tabela 6. Na tabela 7 descrevem-se os erros quadráticos médios resultantes do treinamento das áreas 1, 2 e 3.

Tabela 6 Porcentagem de amostras simuladas fora do intervalo estabelecido

<b>Atributo</b>	<b>% Área 1</b>	<b>% Área 2</b>	<b>% Área 3</b>
<b>PH</b>	2,2	0	4,88
<b>P-rem</b>	2,94	-	-
<b>P</b>	0	1,47	5,71
<b>K</b>	0	0	0
<b>Na</b>	1,19	-	-
<b>Ca</b>	0	8	-
<b>Mg</b>	0	9,02	-
<b>Al</b>	29,01	-	-
<b>H+Al</b>	5,93	5,7	-
<b>SB</b>	1,8	-	-
<b>t</b>	0	-	-
<b>T</b>	5,28	-	-
<b>V</b>	22,5	-	-
<b>m</b>	4,6	-	-
<b>MO</b>	9,32	25,99	27,96
<b>B</b>	0	-	-
<b>S</b>	4,53	10,57	0,97
<b>CE</b>	8,33	-	-

Tabela 7 Erros quadráticos médios

<b>Atributo</b>	<b>Área 1</b>	<b>Área 2</b>	<b>Área 3</b>
<b>Ph</b>	0,0036	0,0001	0,0001
<b>P-rem</b>	3,4644	-	-
<b>P</b>	0,0001	0,0001	0,0001
<b>K</b>	0,0001	0,0001	0,0001
<b>Na</b>	0,0781	-	-
<b>Ca</b>	0,0086	0,0189	-
<b>Mg</b>	0,0065	0,0098	-
<b>AL</b>	0,0001	-	-
<b>H + Al</b>	6,4687	0,0977	-
<b>SB</b>	0,0143	-	-
<b>t</b>	0,0042	-	-
<b>T</b>	3,2008	-	-
<b>V</b>	0,0001	-	-
<b>m</b>	0,7103	-	-
<b>MO</b>	0,7478	0,6506	0,0001
<b>B</b>	0,0001	-	-
<b>S</b>	0,0001	0,0001	0,1227
<b>CE</b>	0,0001	-	-

#### 4.5 Resultados Primeira Simulação

Na Figura 21 estão ilustradas a classificação dos valores, de acordo com Ribeiro e Guimarães (1999), e suas respectivas cores, as quais são utilizadas para as três simulações.

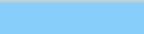
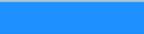
Original	Simulado	
		Muito baixo
		Baixo
		Bom
		Alto
		Muito alto

Figura 21 Classificação dos valores

A seguir, observam-se as imagens das amostras georreferenciadas originais e simuladas, em que é realizada uma breve discussão dos *atributos pH, P-rem, P, K, Na, Ca, Mg, Al, H+Al, SB, t, T, V, m, MO, B, S e CE*, simulados para a área 1. Na Figura 22 observam-se os valores originais do atributo *pH*, os quais apresentam valores de baixos a até muito altos. Na Figura 23, os valores simulados do *pH* também apresentam valores de baixos a até muito altos, com destaque para o centro da área, onde os valores são sempre muito altos.



Figura 22 1a área - Variabilidade do  $ph$  original

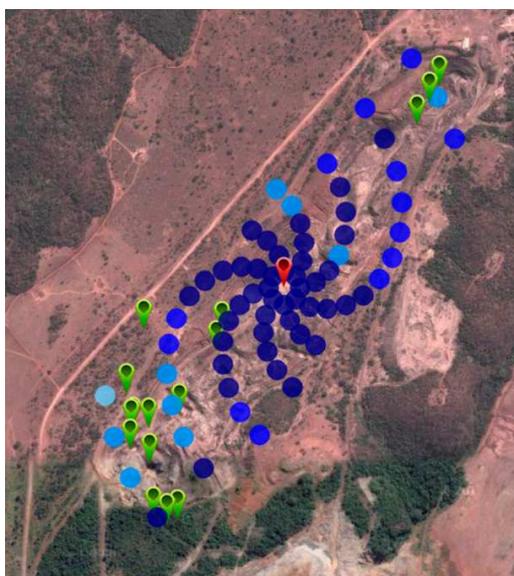


Figura 23 Variabilidade do  $ph$  simulado - 1a área

No atributo *P-rem*, os valores originais são, na maioria, altos e muito altos, como ilustrado na Figura 24, entretanto, os valores simulados têm a mesma característica, de acordo com a Figura 25.



Figura 24 Variabilidade do *p-rem* original- 1a área



Figura 25 Variabilidade do p-rem simulado - 1a área

Na Figura 26 observa-se que o atributo  $P$  está variando entre alto e bom. Já os resultados da simulação (Figura 27) demonstram que, no centro da área, os valores estão muito altos e muito baixos; nas laterais, resultaram valores altos.



Figura 26 Variabilidade do  $p$  original - 1a área

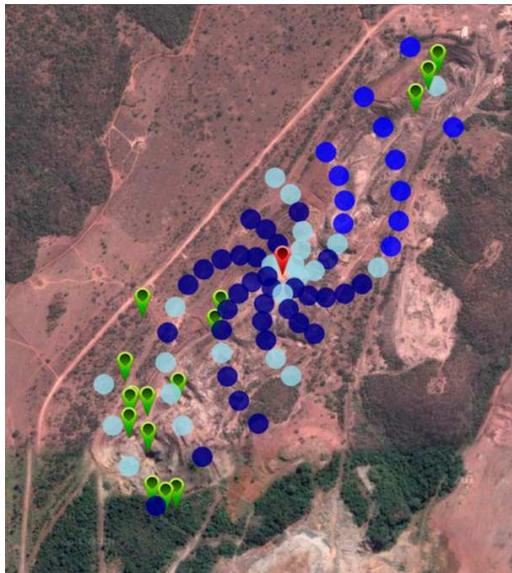


Figura 27 Variabilidade do  $p$  simulado - 1a área

Observando-se a Figura 28, identifica-se que os valores originais do atributo  $k$  permaneceram muito altos, altos e bons. No centro da área, os valores simulados se encontram classificados em baixos e bons e nas laterais, muito altos e altos, como indicado pela Figura 29.



Figura 28 Variabilidade do  $k$  original- 1a área

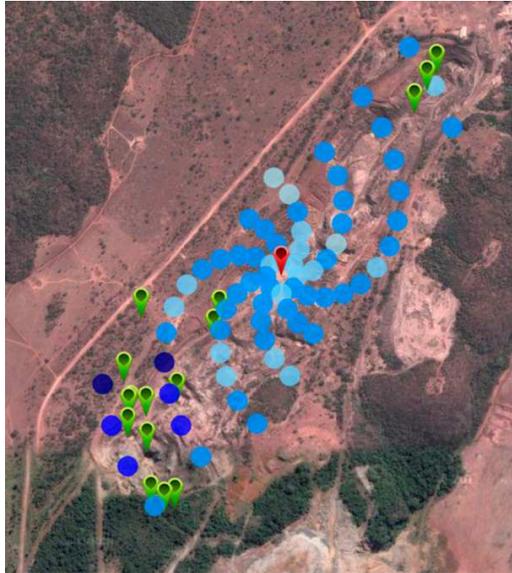


Figura 29 Variabilidade do  $k$  simulado - 1a área

De acordo com a Figura 30, os valores originais do atributo  $Na$  são classificados em altos e uma quantidade mínima, como bons. Os valores simulados descritos na Figura 31 a classificação resultou em valores alto e muito alto.

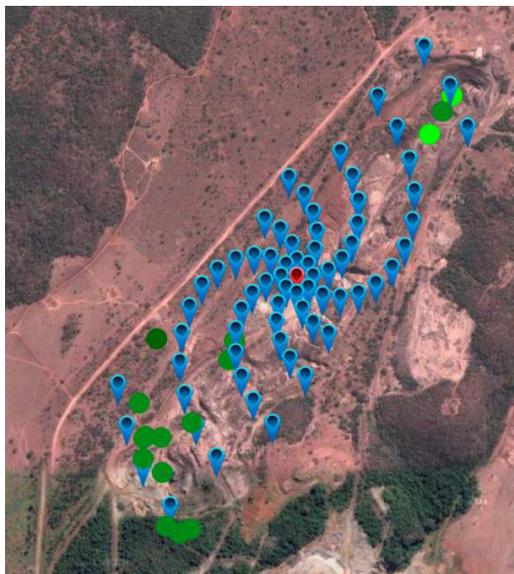


Figura 30 Variabilidade do  $Na$  original - 1a área



Figura 31 Variabilidade do  $Na$  simulado - 1a área

O atributo *Ca* obteve valores originais bons e altos, como descrito na Figura 32 e simulados valores variando entre bons, baixos e altos (33).



Figura 32 Variabilidade do *Ca* original- 1a área

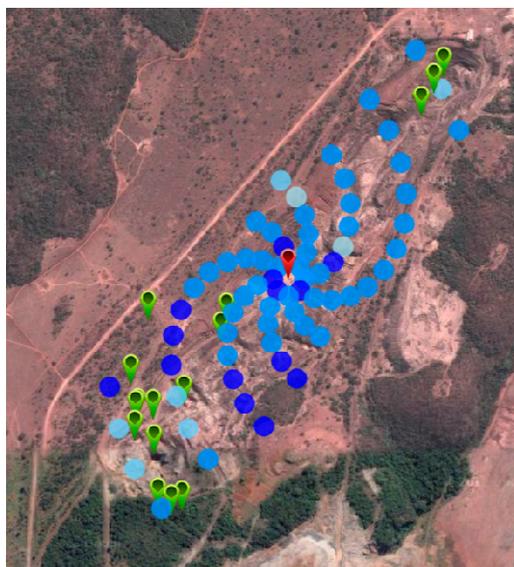


Figura 33 Variabilidade do  $Ca$  simulado - 1a área

Os valores originais do atributo  $Mg$  variaram entre muito altos, altos, bons e baixos e estão representados na Figura 34. A simulação também resultou na classificação de valores representados pela Figura 35.



Figura 34 Variabilidade do  $Mg$  original- 1a área

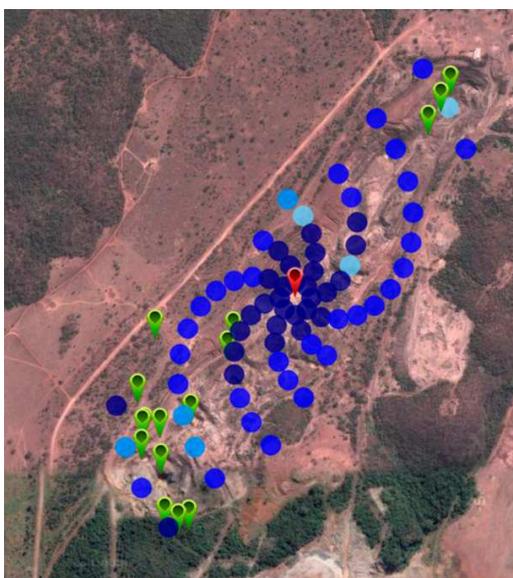


Figura 35 Variabilidade do  $Mg$  simulado - 1a área

O atributo *AI* foi classificado, em seus valores originais, entre bom e baixo, com apenas um ponto considerado alto (Figura 36). A maioria dos valores simulados foi muito baixa, baixa e apenas três pontos foram classificados como altos, como pode ser observado na Figura 37.



Figura 36 Variabilidade do *AI* original - 1a área

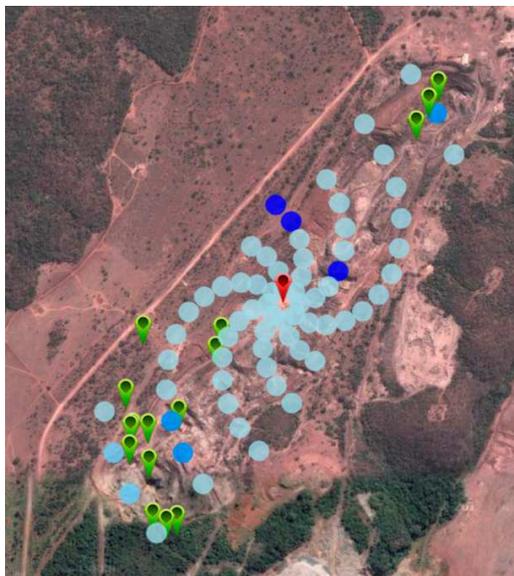


Figura 37 Variabilidade do  $AI$  simulado - 1a área

De acordo com a Figura 38, os valores originais do atributo  $H+AI$  foram classificados entre bons e altos. Entretanto, na Figura 39, foram simulados valores classificados como baixos, bons, altos e muito altos.

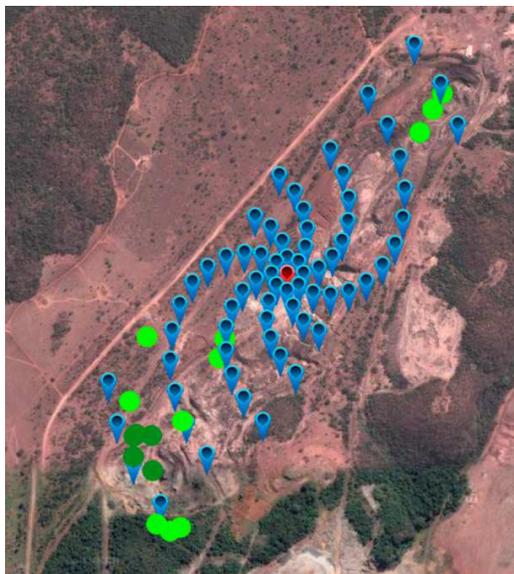


Figura 38 Variabilidade do  $H+Al$  original - 1a área

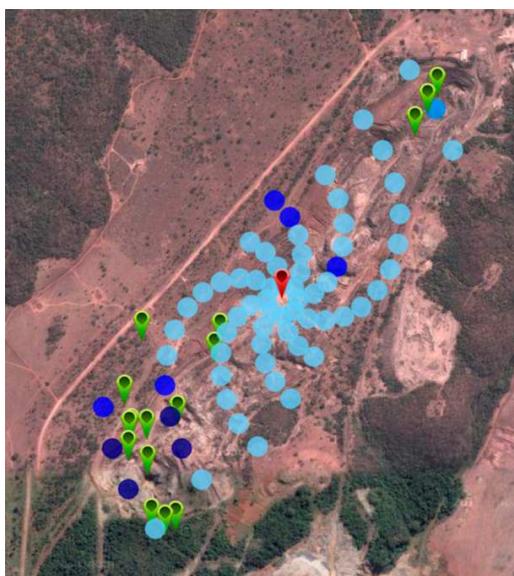


Figura 39 Variabilidade do  $H+Al$  simulado - 1a área

Na Figura 40 estão ilustrados os valores originais do atributo *SB*, os quais foram classificados entre baixos, bons e altos. De acordo com a Figura 41, os valores simulados também foram reproduzidos nesta mesma faixa.

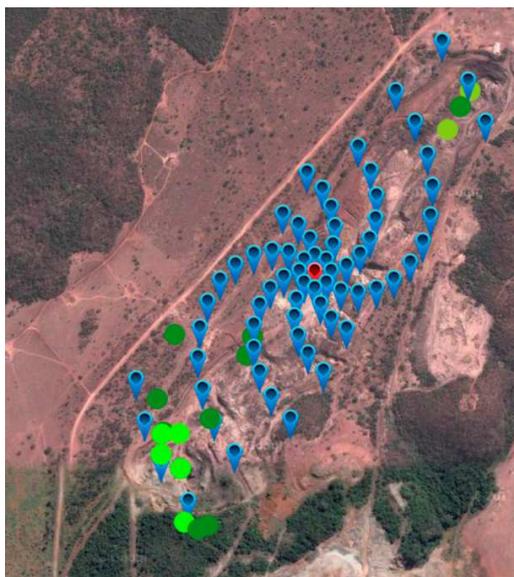


Figura 40 Variabilidade do *SB* original - 1a área

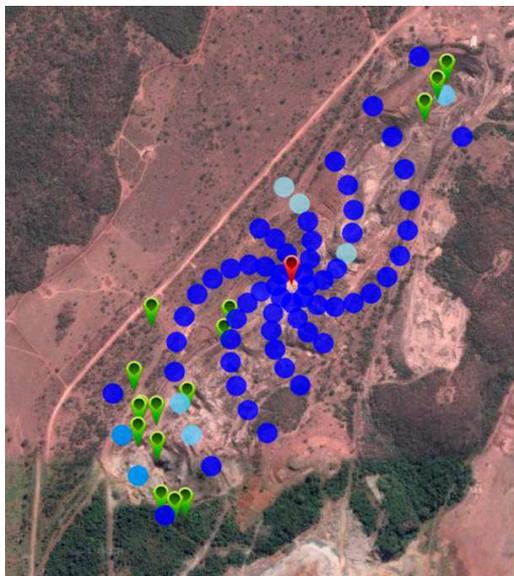


Figura 41 Variabilidade do *SB* simulado - 1a área

Os valores originais do atributo  $t$  descritos na Figura 42 foram classificados entre altos e bons. Assim, os valores simulados também tiveram esta mesma classificação, com exceção de cinco pontos classificados como baixos (Figura 43).



Figura 42 Variabilidade do  $t$  original- 1a área

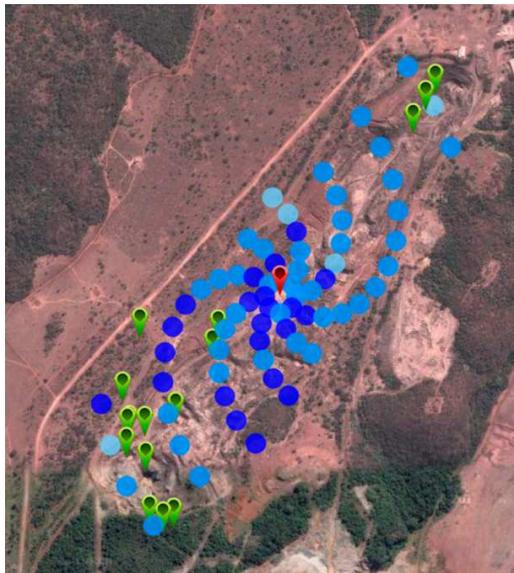


Figura 43 Variabilidade do  $t$  simulado - 1a área

A classificação do atributo  $T$  nos valores originais variou entre alta e boa, como se observa na Figura 44. Contudo, os valores simulados também se mantiveram nesta mesma variação, como ilustrado na Figura 45.



Figura 44 Variabilidade do  $T$  original - 1a área



Figura 45 Variabilidade do  $T$  simulado - 1a área

Os valores originais do atributo  $V$  foram classificados variando entre muito altos, altos, bons e muito baixos, como ilustrado na Figura 46. Os resultados da simulação variaram entre as cinco faixas de valores da classificação, como observado na Figura 47.

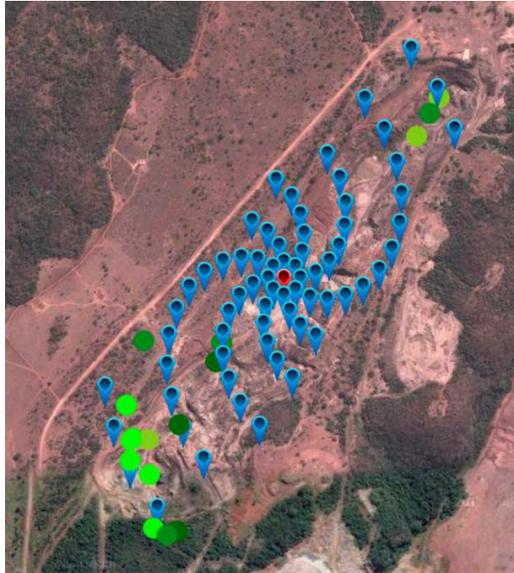


Figura 46 Variabilidade do  $V$  original - 1a área

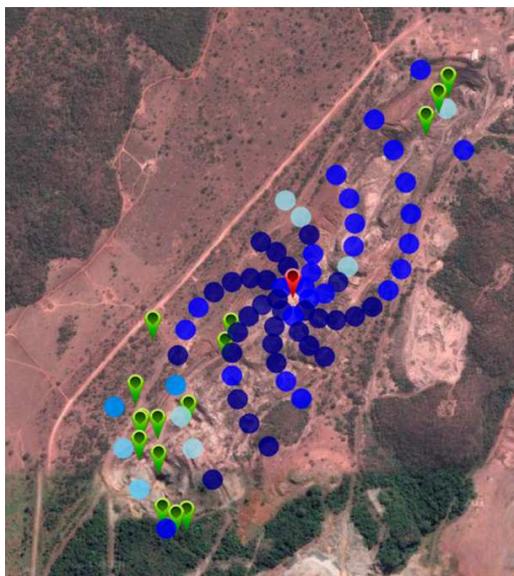


Figura 47 Variabilidade do  $V$  simulado - 1a área

A Figura 48 demonstra que o atributo  $m$  foi classificado nos valores originais entre baixo, bom e alto. Na simulação, a maioria dos valores foi muito baixa, tendo apenas dois pontos sido classificados como baixos e quatro pontos muito altos, como se observa na Figura 49.



Figura 48 Variabilidade do  $m$  simulado - 1a área



Figura 49 Variabilidade do  $m$  simulado - 1a área

Os dados originais do atributo  $MO$  indicam que estão classificados como bons, baixos e muito baixos (Figura 50). A simulação dos valores na Figura 51 demonstra que os valores estão muito baixos no centro da área, variando entre baixo e bom, ao se expandir para as laterais.

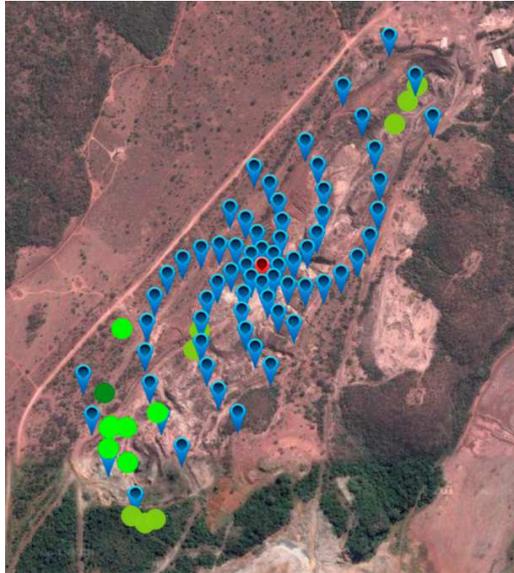


Figura 50 Variabilidade do *MO* original - 1a área

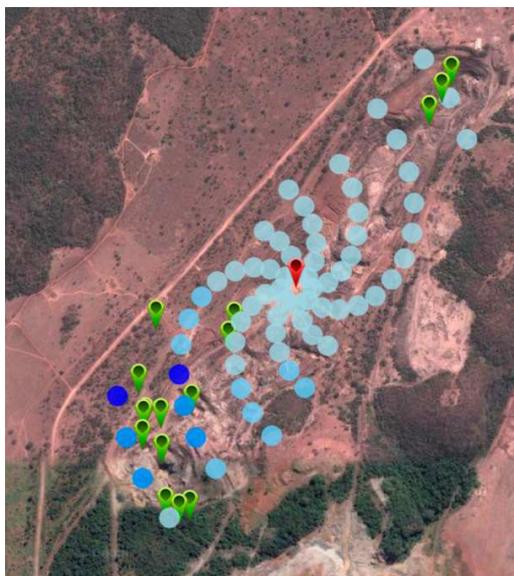


Figura 51 Variabilidade do *MO* simulado - 1a área

A classificação do atributo  $B$ , nos valores originais, variou entre bom e baixo, como ilustrado na Figura 52. Os valores simulados foram classificados entre muito baixo e baixo, com exceção de dois pontos classificados bons, como se observa na Figura 53.



Figura 52 Variabilidade do  $B$  original - 1a área

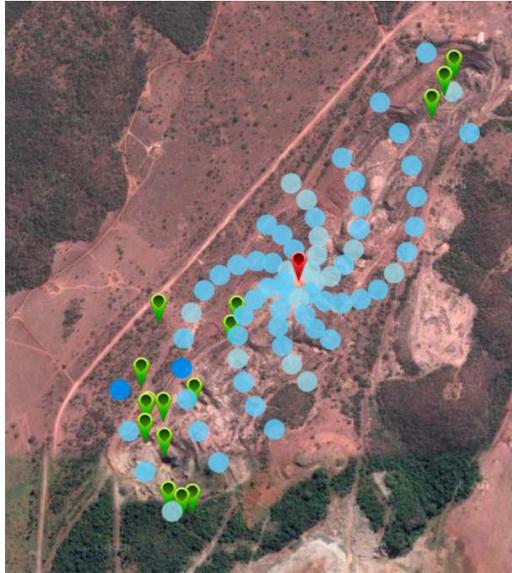


Figura 53 Variabilidade do  $B$  simulado - 1a área

O atributo  $S$ , nas amostras originais, apresentou valores muito altos e altos, como descrito na Figura 54. Nas amostras simuladas existe uma intercalação de valores que variam entre muito altos, altos e muito baixos (Figura 55).

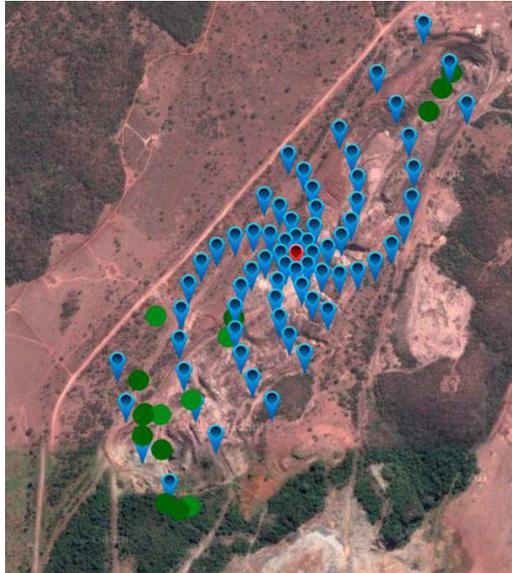


Figura 54 Variabilidade do  $S$  original - 1a área



Figura 55 Variabilidade do  $S$  simulado - 1a área

Como se observa na Figura 56, os valores nas amostras originais do atributo *CE* foram classificados como altos e muito altos. A simulação resultou em valores muito altos, altos e muito baixos (Figura 57).

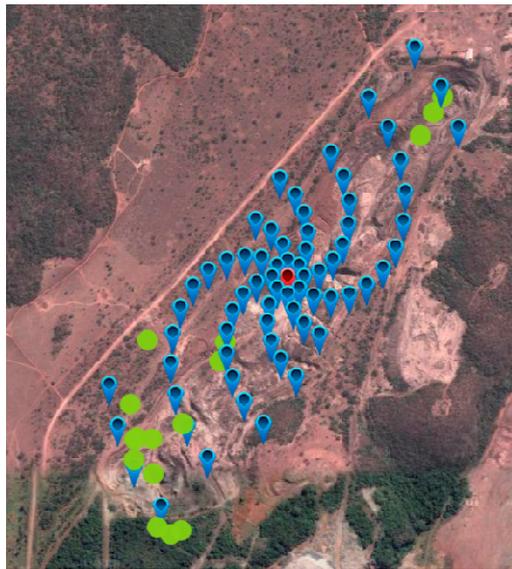


Figura 56 Variabilidade do *CE* original - 1a área



Figura 57 Variabilidade do *CE* simulado - 1a área

#### 4.6 Resultados Segunda Simulação

Na segunda área foram simulados os atributos *pH*, *K*, *Ca*, *Mg*, *H+Al*, *MO* e *S*. Na sequência discute-se cada atributo simulado em comparação com o valor original. A classificação dos valores originais no atributo *Ph*, descritos na Figura 58, variou entre alto, bom e baixo. Na simulação descrita pela Figura 59 possuem a mesma variação.

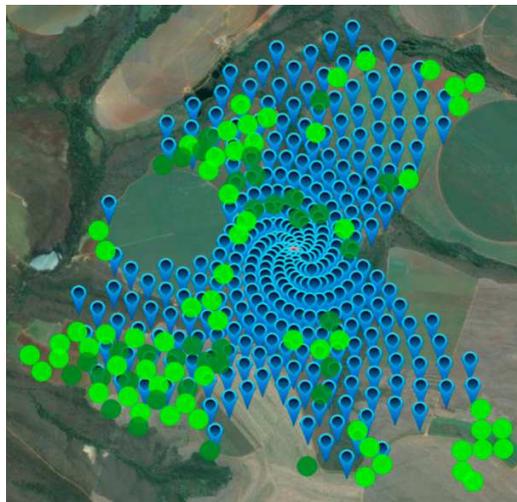


Figura 58 Variabilidade do  $Ph$  original - 2a área

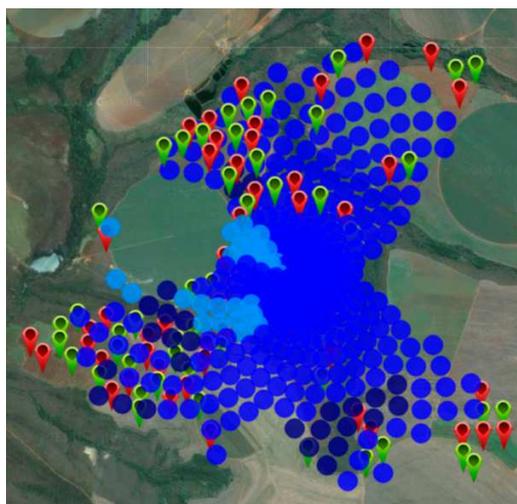


Figura 59 Variabilidade do  $Ph$  simulado - 2a área

Na Figura 60 está ilustrada a classificação dos valores do atributo  $K$ , indicando que estão variando entre muito altos e altos, e apenas três amostras

classificadas com valor bom. A classificação na Figura 61 também varia nestas três faixas.

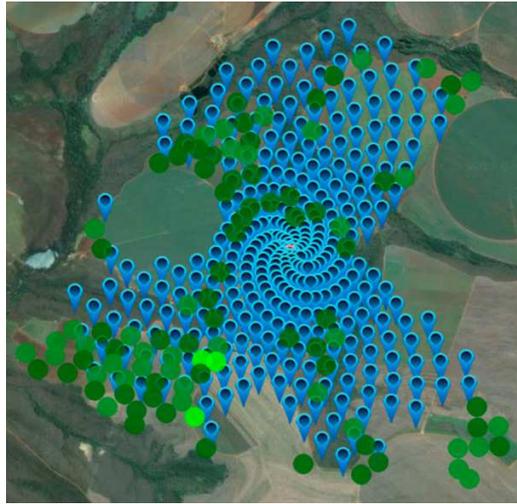


Figura 60 Variabilidade do  $K$  original - 2a área

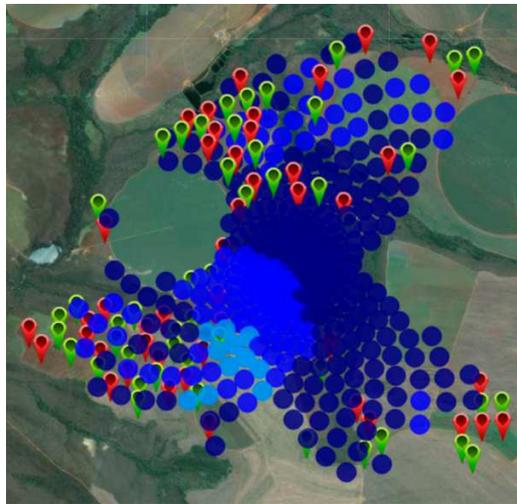


Figura 61 Variabilidade do  $K$  simulado - 2a área

A classificação dos valores originais do atributo *Ca* descritos na Figura 62 e simulados na Figura 63 varia entre alto e bom.

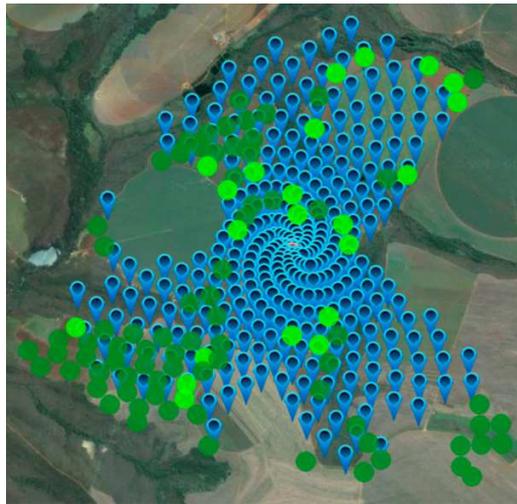


Figura 62 Variabilidade do *Ca* original - 2a área

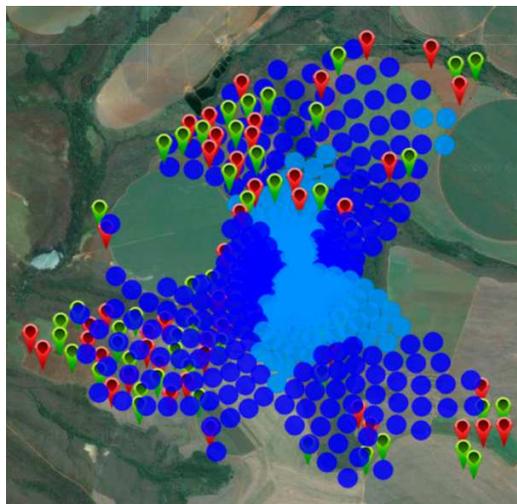


Figura 63 Variabilidade do *Ca* simulado - 2a área

Na Figura 64 observa-se a variação da classificação dos valores originais do atributo *Mg* fixada em muito alto, alto e bom. No entanto a simulação resultou em valores muito altos, altos, bons e baixos, ilustrados na Figura 65.

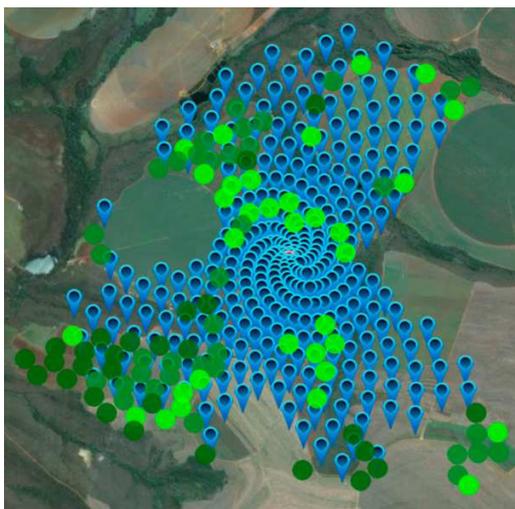


Figura 64 Variabilidade do *Mg* original - 2a área

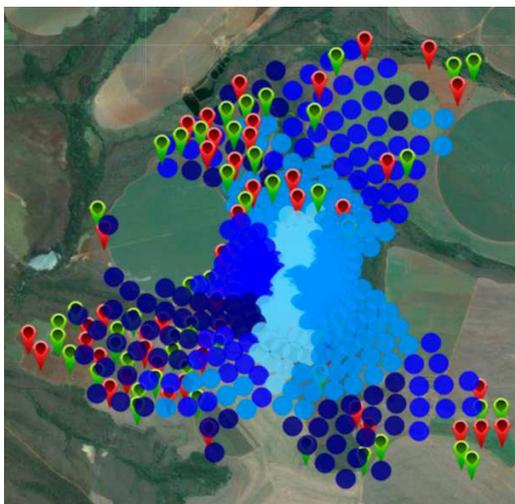


Figura 65 Variabilidade do *Mg* simulado - 2a área



A classificação dos valores originais do atributo  $H+Al$  variaram entre alto e bom, como descrito na Figura 66. De acordo com a Figura 67 os valores simulados também se mantiveram entre alto e bom, com exceção de uma amostra simulada com valor muito alto.

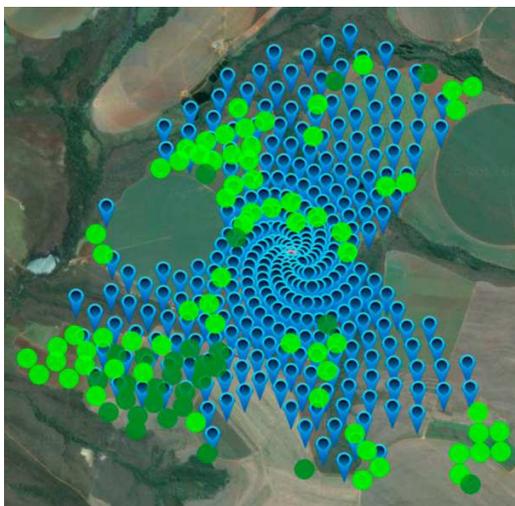


Figura 66 Variabilidade do  $H+AL$  original - 2a área

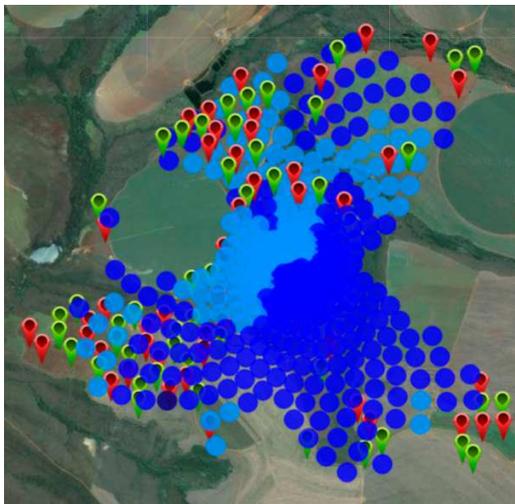


Figura 67 Variabilidade do  $H+Al$  simulado - 2a área

A Figura 68 descreve a classificação dos valores originais do atributo  $MO$  indicando que estão entre alto e bom. Na Figura 69 tais valores foram simulados como muito alto, alto e bom.

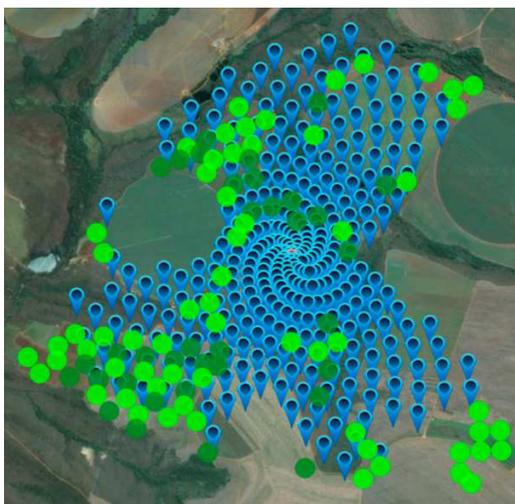


Figura 68 Variabilidade do  $MO$  original - 2a área

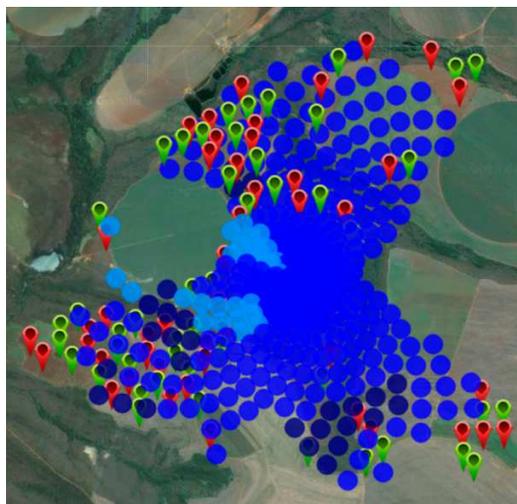


Figura 69 Variabilidade do *MO* simulado - 2a área

Os valores originais do atributo *S*, como descrito na Figura 70, estão classificados como muito alto, alto e bom. Contudo a simulação resultou em valores os quais podem ser classificados como muito altos, altos, bons e baixos, como observado na Figura 71.

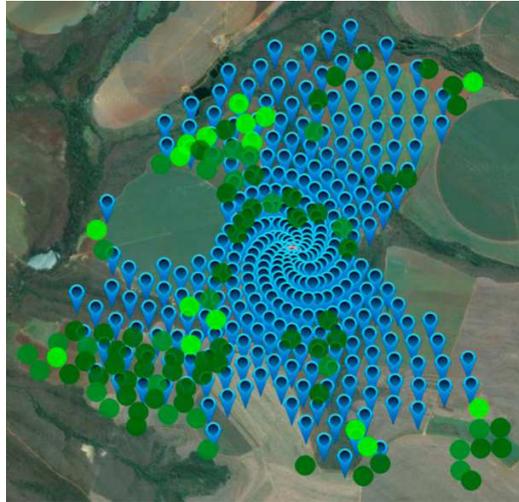


Figura 70 Variabilidade do  $S$  original - 2a área

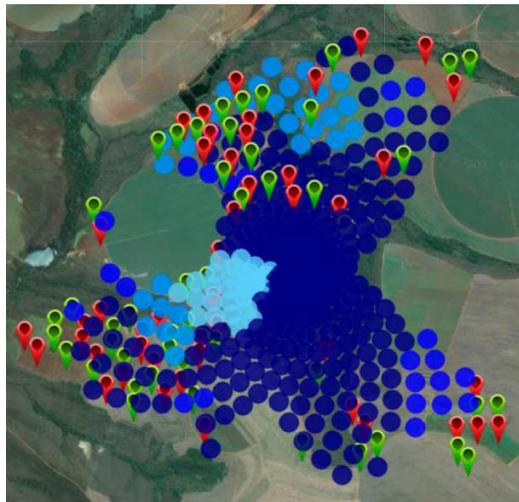


Figura 71 Variabilidade do  $S$  simulado - 2a área

#### 4.7 Resultados Terceira Simulação

Na terceira área foram simulados os atributos  $Ph$ ,  $K$ ,  $MO$  e  $S$ , que resultou nas imagens a seguir, as quais descrevem a distribuição de pontos e os valores de cada atributo. Os valores originais do atributo  $Ph$  foram classificados entre alto e bom, descritos na Figura 72, os resultados da simulação ilustrados na Figura 73 indicam que grande parte dos pontos possuem o  $Ph$  alto e apenas doze amostras foram classificadas como bom.



Figura 72 Variabilidade do  $Ph$  original - 3a área



Figura 73 Variabilidade do  $Ph$  simulado - 3a área

No atributo  $K$  a classificação dos valores originais variam entre muito alto e alto, como observados na Figura 74, os valores simulados descritos na Figura 75 também variaram entre muito alto e alto.

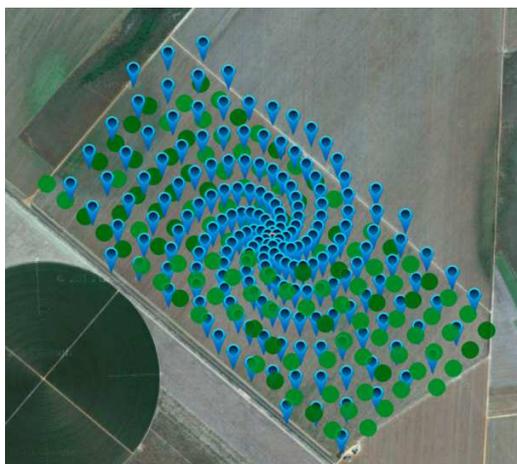


Figura 74 Variabilidade do  $K$  original - 3a área

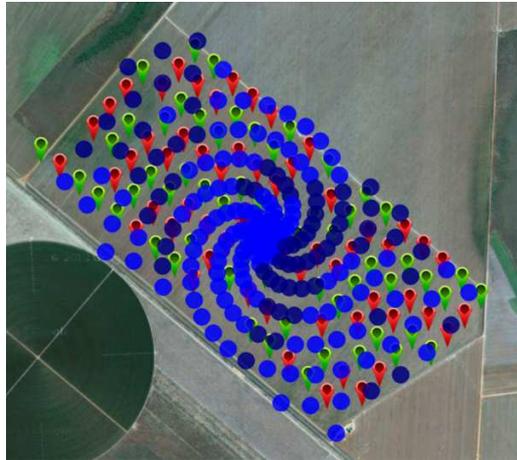


Figura 75 Variabilidade do  $K$  simulado - 3a área

A Figura 76 e Figura 77 descrevem que o atributo  $MO$  está classificado como bom tanto nos valores originais quanto simulados.



Figura 76 Variabilidade do  $MO$  original - 3a área



Figura 77 Variabilidade do *MO* simulado - 3a área

Os valores do atributo *S*, originais, foram classificados numa variação entre muito alto, alto e bom. Observou-se que os valores classificados bons se deram por amostras posicionadas numa mesma região do mapa, como descrito na Figura 78. Na simulação foram observados a mesma variação, conforme ilustrado na Figura 79. Desse modo, identificou-se que os valores que menos variam foram melhores representados pela simulação, embora os que variam também foram reproduzidos pelo SNF com pequenas diferenças.



Figura 78 Variabilidade do  $S$  original - 3a área

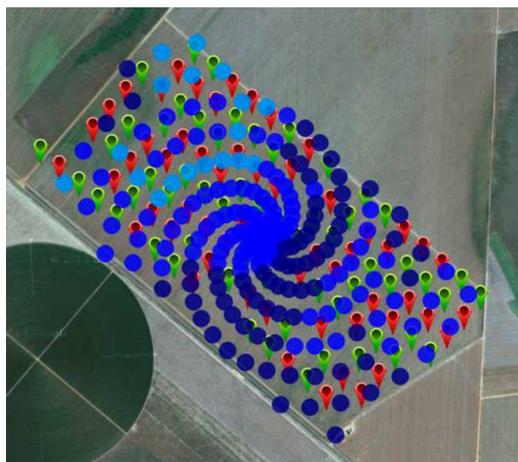


Figura 79 Variabilidade do  $S$  simulado - 3a área

#### 4.8 Análise comparativa

A arquitetura do modelo adaptativo neuro-fuzzy de Kisi et al. (2009) foi projetada com cinco camadas, intercalando regras de inferência fuzzy e modelos

neurais. Com esta estrutura, o modelo gerou melhores resultados em comparação com outros modelos. A simulação de atributos de solos também utilizou uma arquitetura com cinco camadas, porém, com apenas uma camada de inferências fuzzy, entretanto, gerou resultados satisfatórios com erros absolutos próximos de zero e erros quadráticos médios também tendendo a zero, na simulação da área 3. Os resultados das simulações apresentaram variações significativas considerando as três áreas distintas. As simulações nas áreas 2 e 3 se mostraram mais efetivas do que na área 1, fato este explicado pela forma de coleta das amostras utilizadas no treinamento do SNF, que não conseguiu representar a variabilidade dos valores. É necessário obter uma quantidade de amostras de solo que consiga mapear de forma adequada a variabilidade dos valores a serem simulados. A quantidade de amostras deve ser obtida de forma que represente a heterogeneidade da área para obter amostras representativas para o aprendizado do modelo.

## 5 CONCLUSÃO

- a) a ferramenta Reabilite auxilia o mapeamento de atributos de solos para o planejamento de intervenções que beneficiem o processo de recuperação natural;
- b) a ferramenta Reabilite proporciona um ambiente agradável e interativo para visualizar pontos georreferenciados no *Google maps* e provê uma plataforma robusta para a realização de análises dos resultados obtidos da simulação, bem como a classificação de valores coletados de forma efetiva;
- c) o Sistema de Simulação Neuro-*fuzzy* adaptativo mostrou-se adequado para o mapeamento de valores simulados de atributos físicos e químicos de solos;
- d) os resultados das simulações nas áreas de agricultura de precisão foram satisfatórios, ou seja, a simulação representou 78% e 80%, nas áreas 2 e 3, respectivamente, das amostras em todos os atributos simulados.

## REFERÊNCIAS

- ABDO, M. T. V. N. **Recuperação de solos degradados pela agricultura**. Disponível em: <<http://www.infobibos.com>>. Acesso em: 10 mar. 2013.
- AKRAMI, S. A.; EL-SHAFIE, A.; JAAFAR, O. Improving rainfall forecasting efficiency using modified adaptive neuro-fuzzy inference system (manfis). **Water Resources Management**, New York, v. 27, n. 9, p. 3507-3523, July 2013.
- ALVES, E.; SILVA NETO, R. e. Plano básico para o desenvolvimento da silvicultura sustentável. In: ALVES, E. (Ed.). **Regiões Norte e Noroeste do Estado do Rio de Janeiro**. Rio de Janeiro: SEPLAG, 2011. v. 3, p. 200.
- ANDERSON, B. N.; HOWARTH, R. W.; WALKER, L. R. **Linking restoration and ecological succession**. New York: Springer, 2007. 200 p.
- BENAYAS, J. M. R. et al. Enhancement of biodiversity and ecosystem services by ecological restoration: a meta analysis. **Science**, New York, v. 325, p. 1121-1124, Aug. 2009.
- BETIATTO, A. **Modelagem e simulação**. Disponível em: <[http://www.linecon.com.br/biblioteca/artigo\\_simulacaomanufatura-01\\_linecon.pdf](http://www.linecon.com.br/biblioteca/artigo_simulacaomanufatura-01_linecon.pdf)>. Acesso em: 10 mar. 2013.
- BISHOP, C. M. **Neural networks for pattern recognition**. Oxford: Oxford University, 2008. 482 p.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2007. 226 p.

CHAER, G. M. et al. **Nitrogen-fixing legume tree species for the reclamation of severely degraded lands in Brazil**. Brasília: EMBRAPA Agrobiologia, 2011. 11 p.

CHAZDON, R. L. Beyond deforestation: restoring forest and ecosystem services on degraded lands. **Science**, New York, v. 320, p. 4, June 2008. Disponível em: <<http://www.sciencemag.org>>. Acesso em: 15 mar. 2013.

CHAZDON, R. L. **Tropical forest recovery: legacies of human impact and natural disturbances**. Storrs: Urban; Fischer Verlag, 2003. 20 p. Disponível em: <<http://www.urbanfischer.de/journals/ppees>>. Acesso em: 12 abr. 2013.

CHWIF, L.; MEDINA, A. C. **Modelagem e simulação de eventos discretos: teorias e aplicações**. 3. ed. São Paulo: Ed. dos Autores, 2010. 320 p.

COBANER, M.; UNAL, B.; KISI, O. Suspended sediment concentration estimation by an adaptive neuro-fuzzy and neural network approaches using hydrometeorological data. **Journal of Hydrology**, Amsterdam, v. 367, n. 1/2, p. 52-61, Mar. 2009.

COOPER, M. **Degradação e recuperação de solos**. Piracicaba: ESALQ, 2008. 31 p.

DOBSON, A. P.; BRADSHAW, A. D.; BAKER, A. J. M. Hopes for the future: restoration ecology and conservation biology. **Science**, New York, v. 277, p. 9, July 1997. Disponível em: <<http://www.sciencemag.org>>. Acesso em: 2 abr. 2013.

DUTTA, R.; TERHORST, A. Adaptive neuro-fuzzy inference system-based remote bulk soil moisture estimation: using cosmoz cosmic ray sensor. **IEEE Sensors**, New York, v. 13, n. 6, p. 2374-2381, June 2013.

FERREIRA, L. **Aplicação de sistemas Fuzzy e Neuro-Fuzzy para predição da temperatura retal de frangos de corte**. Lavras: UFLA, 2009. Disponível em: <<http://www.prpg.ufla.br/ppg/esistemas/adm/upload/file/dissertacaofinal.pdf>>. Acesso em: 12 abr. 2013.

FREIMAN, J. P.; PAMPLONA, E. de O. Redes neurais artificiais na previsão do valor de commodity do agronegócio. In: ENCUESTRO INTERNACIONAL DE FINANZAS, 5., 2005, Santiago. **Anales...** Santiago: USACH, 2005. p. 14.

FREITAS, P. J. **Introdução à modelagem e simulação de sistemas com aplicações em Arena**. Florianópolis: Visual Books, 2008. 372 p.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.

KISI, O. et al. Adaptive neuro-fuzzy computing technique for suspended sediment estimation. **Advances in Engineering Software**, Essex, v. 40, n. 6, p. 438-444, June 2009.

LAMB, D.; ERSKINE, P. D.; PARROTTA, J. A. Restoration of degraded tropical forest landscapes. **Science**, New York, v. 310, n. 1628, p. 6, Dec. 2005. Disponível em: <<http://www.sciencemag.org>>. Acesso em: 10 mar. 2013.

POMMERENING, A.; MURPHY, S. A review of the history, definitions and methods of continuous cover forestry with special attention to afforestation and restocking. **School of Agricultural and Forest Sciences**, Zollikofen, v. 77, n. 1, p. 27-44, Nov. 2004.

PRACH, K. et al. **Linking restoration and ecological succession**: chapter manipulation of succession. New York: Springer, 2007. 149 p.

RAJAEI, T. et al. Daily suspended sediment concentration simulation using ANN and neuro-fuzzy models. **Science of the Total Environment**, Amsterdam, v. 407, n. 17, p. 4916-4927, Aug. 2009.

RIBEIRO, A. C.; GUIMARÃES, P. T. G. **Comissão de fertilidade do solo do Estado de Minas Gerais**: recomendações para o uso de corretivos e fertilizantes em Minas Gerais: 5ª aproximação. Viçosa, MG: UFV, 1999. 359 p.

RIBEIRO, N. et al. **Manual de silvicultura tropical**. Maputo: Universidade Eduardo Mondlane, 2002. 121 p.

SAKURADA, N.; MIYAKE, D. I. Estudo comparativo de softwares de simulação de eventos discretos aplicados na modelagem de um exemplo de loja de serviços. In: ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 23., 2003, Ouro Preto. **Anais...** Ouro Preto: ENEGEP, 2003. p. 8.

SAMPAIO, A. B.; HOLLAND, K. D.; SCARIOT, A. Does restoration enhance regeneration of seasonal deciduous forests in pastures in Central Brazil? **Restoration Ecology**, Malden, v. 15, n. 3, p. 462-471, Sept. 2007.

SILVA, R. A. C. **Inteligência artificial aplicada a ambientes de engenharia de software: uma visão geral**. Lavras: UFLA, 2005. Disponível em: <<http://www.dcc.ufla.br/infocomp/artigos/v4.4/art04.pdf>>. Acesso em: 14 mar. 2013.

SIMÕES, M. G.; SHAW, I. S. **Controle e modelagem fuzzy**. São Paulo: Blucher; FAPESP, 2007. 200 p.