

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**  
**CURSO DE ENGENHARIA FLORESTAL**

**ALINE BERNARDA DEBASTIANI**

**PREDIÇÃO DE ÁREAS DE RISCOS DE DESLIZAMENTO USANDO A**  
**REDE NEURAL ARTIFICIAL COMO CRITÉRIO DE DECISÃO**

**TRABALHO DE CONCLUSÃO DE CURSO**

**DOIS VIZINHOS**  
**2013**

**ALINE BERNARDA DEBASTIANI**

**PREDIÇÃO DE ÁREAS DE RISCOS DE DESLIZAMENTO USANDO A  
REDE NEURAL ARTIFICIAL COMO CRITÉRIO DE DECISÃO**

Trabalho de Conclusão de Curso de Graduação, apresentado à disciplina de Trabalho de Conclusão de Curso II, do Curso Superior de Engenharia Florestal da Universidade Tecnológica Federal do Paraná – UTFPR Câmpus Dois Vizinhos, como requisito parcial para obtenção do título de Engenheiro Florestal.

Orientador: Dr. Mosar Faria Botelho

**DOIS VIZINHOS  
2013**

D286p Debastiani, Aline Bernarda.  
Predição de áreas de risco de deslizamento usando a rede neural artificial como critério de decisão / Aline Bernarda Debastiani – Dois Vizinhos :[s.n], 2013.  
71 f.:il.

Orientador: Mosar Faria Botelho  
Trabalho de Conclusão de Curso (graduação) -  
Universidade Tecnológica Federal do Paraná. Curso de  
Engenharia Florestal. Dois Vizinhos, 2013.  
Bibliografia p.65-71

1.RNA- Rede Neural Artificial. 2.Deslizamentos-  
áreas de risco I.Botelho, Mosar Faria, orient.  
II.Universidade Tecnológica Federal do Paraná– Dois  
Vizinhos.III.Título

CDD: 621.3678

Ficha catalográfica elaborada por Rosana Oliveira da Silva CRB: 9/1745

Biblioteca da UTFPR-Dois Vizinhos



Ministério da Educação  
**Universidade Tecnológica Federal do Paraná**  
Câmpus Dois Vizinhos  
Curso de Engenharia Florestal



---

## **TERMO DE APROVAÇÃO**

**PREDIÇÃO DE ÁREAS DE RISCOS DE DESLIZAMENTO USANDO A REDE NEURAL  
ARTIFICIAL COMO CRITÉRIO DE DECISÃO**

por

**ALINE BERNARDA DEBASTIANI**

Este Trabalho de Conclusão de Curso foi apresentado em 27 de março de 2013 como requisito parcial para a obtenção do título de bacharel em Engenharia Florestal. A candidata foi arguida pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

---

Prof. Dr. Mosar Faria Botelho  
Orientador

---

Prof<sup>ª</sup> Dr<sup>ª</sup> Fabiani D. A. Miranda  
Membro titular (UTFPR)

---

Prof. Dr. Laércio Ricardo Sartor  
Membro titular (UTFPR)

- O Termo de Aprovação assinado encontra-se na Coordenação do Curso -

## **AGRADECIMENTOS**

Em primeiro lugar á Deus, fonte da ciência, por toda força nessa caminhada.

À minha família pelo amor, dedicação, estarem sempre presente e compreensão na minha ausência.

Aos colegas e amigos Maurício de Souza, Ricardo Dal'agnol e Karina Guollo que colaboraram no desenvolvimento desse estudo.

Ao meu namorado Mauro Acordi Junior pela colaboração, companheirismo e paciência.

Ao professor Dr. Mosar Faria Botelho pelas horas de orientação, aprendizado, motivação, que, juntas, culminaram no conhecimento agregado para a realização desse trabalho.

Á Fundação Araucária, financiadora de minha bolsa de iniciação científica (PIBIC) a qual estou vinculada e que me possibilita o contato com a pesquisa.

A todas as pessoas que de uma forma ou outra colaboraram com esta pesquisa.

## RESUMO

DEBASTIANI, ALINE B. Predição de áreas de riscos de deslizamento usando a rede neural artificial como critério de decisão. 2013. 71 f. Trabalho de Conclusão de Curso (Graduação) – Curso Superior de Engenharia Florestal. Universidade Tecnológica Federal do Paraná, Dois Vizinhos, 2013.

Os deslizamentos no mundo inteiro têm causado grandes perdas econômicas e sociais. Com o uso de geotecnologias associadas ao potencial de inteligência artificial acredita-se que se possa prevenir ou amenizar os impactos causados por tal evento. Este trabalho teve objetivo testar a técnica da rede neural artificial (RNA) para verificar se a mesma é capaz de aprender os padrões existentes nas áreas de risco, e se é possível aplicar este aprendizado para verificar áreas com potencial para desmoronar, tanto na mesma área quanto em outra com algumas características diferentes. Portanto, buscou-se junto aos órgãos competentes do estado por ocorrência de deslizamento e a sua localização espacial, além de informações referentes ao uso e ocupação do solo, imagem espectral, classe de solo, declividade, hidrografia, direção do fluxo e comprimento do fluxo do mesmo local de ocorrência dos eventos, estas informações foram atribuídas na camada de entrada da RNA. Para maximizar o desempenho de aprendizagem da RNA, foram verificadas diferentes arquiteturas empiricamente. O melhor resultado para o aprendizado correspondeu a 91,66% de acerto que foi passado para a simulação. A simulação foi aplicada para uma parte da área que foi utilizada como treinamento e para o município de Dois Vizinhos, que corresponde a uma área com características diferentes da área de treinamento. A RNA encontrou um modelo para os padrões das áreas de risco apresentados e verificou-se que esses padrões ocorrem também em diferentes regiões das quais a arquitetura da RNA foi treinada pois apresentam alguma semelhança em seus dados espectrais ou espaciais. Portanto, esses resultados podem auxiliar os órgãos gestores na tomada de decisão quanto a prevenção de áreas com potencial a risco de desmoronamento.

Palavras-chave: ASTER GDEM. Movimento de massa. Rede neural artificial.

## ABSTRACT

DEBASTIANI, ALINE B. Prediction Of Landslide Risk Areas Using Artificial Neural Network As Decision Criterion. 2013. 71 f. Completion of course work (Graduation) - Degree in Forest Engineering. Federal Technological University of Paraná, Dois Vizinhos, 2013.

Landslides all over the world have been causing big losses both economically and in lives. With the use of geotechnologies associated to the potential of the artificial intelligence is believed that it is possible to prevent or mitigate the impacts caused by such event. The objective is to test the ANN technique to verify if it is able to learn the existent patterns in the risk areas, and if it is possible to apply this learning to verify areas with landslide potential, both in the same area as in another one with some different characteristics. For this, was researched with the competent organs of the estate for the occurrence of landslides and its spatial location, information about the use and occupancy of the land, spectral image, land class, slope, hydrography, direction and length of the flow in the same place of the events occurrence. The information was introduced in the input layer of the ANN. To maximize the ANN learning rate, different architectures were verified empirically. The best result for the learning corresponded to 91.66% of success that was passed to the simulation. The simulation was applied in a part of the area that was used for training and for the city of Dois Vizinhos, that corresponds to an area with different characteristics from the training area. The ANN found a model for the patterns of the risk areas presented and was verified that these patterns also happens in different regions from those where the ANN architecture was trained because they have some similarities in their spectral or spatial data. Therefore, these results can help the managing organs in the decision making regarding to the prevention in areas with potential landslide risk.

Keywords: ASTER GDEM. Mass movement. Artificial neural network.

## LISTA DE SIGLAS

AHP	Processo Analítico Hierárquico
AMSOP	Associação de municípios do sudoeste do Paraná
ASTER	Advanced Spacebourne Thermal Emission and Reflection Radiometer (Radiômetro Espacial Avançado de Emissões Térmicas e Reflexão)
BA	Bahia
ERSDAC	Earth Remote Sensing Data Analysis Center
FS	Fator de Segurança
HRG	High Geometric Resolution
HRS	High Resolution Stereoscopic
HRVIR	High Resolution Visible and Infra-Red (Alta resolução visível e infra-vermelho)
INPE	Instituto Nacional de Pesquisa Espacial
IV	Infra-vermelho
MAXVER	Máxima Verossimilhança
MDE	Modelo Digital de Elevação
MDT	Modelo Digital do Terreno
METI	Ministério da Economia, Comércio e Indústria do Japão
MG	Minas Gerais
MNT	Modelo Numérico do Terreno
NDVI	Normalized Difference Vegetation Index
NGA	National Geospatial-Intelligence Agency
RADARSAT	Sistemas Orbitais de Monitoramento e Gestão Territorial
RGB	Red, Green, Blue (Vermelho, Verde, Azul)
RMS	Erro Médio Quadrático
RMSE	Root-Mean-Square Error
RNA	Rede Neural Artificial
SIG	Sistema de Informação Geográfica
SPOT	Système Probatoire d'Observation de La Terre (Sistema de Estágio de Observação da Terra)
SR	Sensoriamento Remoto
SRTM	Shuttle Radar Topography Mission



## LISTA DE FIGURAS

Figura 1 - Estrutura da RNA.....	30
Figura 2 - Representação da área de ocorrência de deslizamento utilizada como área de aprendizado da RNA. ....	32
Figura 3 - Aproximação dos municípios que fazem parte da área utilizada como aprendizado da RNA.....	33
Figura 4 - Representação da localização de Dois Vizinhos sobre a imagem do estado do Paraná. ....	34
Figura 5 - Processamentos realizados com os mapas.....	36
Figura 6 - Processamentos realizados.....	37
Figura 7 - Imagem da localização das ocorrências de deslizamento no estado do Paraná. ....	41
Figura 8 - Imagem de satélite da região de ocorrência de deslizamento no estado do Paraná. ....	42
Figura 9 - Imagem do uso e ocupação do solo na área de treinamento da RNA.....	43
Figura 10 - Classes de solo na área de treinamento da RNA. ....	44
Figura 11 – Grau de inclinação do terreno próximo ao litoral do estado do Paraná. ....	45
Figura 12 – Mapa da direção do fluxo.....	46
Figura 13 – Mapa do comprimento do fluxo.....	47
Figura 14 - Informação de hidrografia. ....	48
Figura 15 - Imagem espectral do município de Dois Vizinhos, esta do satélite SPOT/5, datada de 2008. ....	49
Figura 16 - Imagem de uso e ocupação do solo de Dois Vizinhos.....	50
Figura 17 - Classificação de solos para Dois Vizinhos. ....	51
Figura 18 - Declividade para o município de Dois Vizinhos .....	52
Figura 19 - Direção do fluxo para o município de Dois Vizinhos. ....	53
Figura 20 - Informação de comprimento de fluxo para o município de Dois Vizinhos.....	54
Figura 21 - Identificação dos reservatórios de água para o município de Dois Vizinhos. ....	55
Figura 22 – Recorte realizado sobre a área de ocorrência utilizado para realizar a simulação.....	58
Figura 23 – Resultado do apontamento de possíveis áreas de deslizamento, na região de ocorrência de deslizamento. ....	59
Figura 24 – Resultado da simulação da RNA para a cidade de Dois Vizinhos.....	60
Figura 25 – Resultado da gravidade do deslizamento apontado pela RNA para o município de Dois Vizinhos. ....	60

## LISTA DE TABELAS

Tabela 1 - Intervalo de aceitação dos resultados do índice Kappa.....	22
Tabela 2 - Resultados da RNA para os dados de ocorrência, não ocorrência e dúvida. ....	56
Tabela 3 - Acertos da RNA. ....	56
Tabela 4 - Classificação errônea pela RNA. ....	57
Tabela 5 - Avaliação da simulação.....	61

## SUMÁRIO

<b>1 INTRODUÇÃO .....</b>	<b>11</b>
1.2 OBJETIVO .....	12
1.2.1 Objetivo Geral .....	12
1.2.2 Objetivos Específicos .....	13
<b>2 REVISÃO BIBLIOGRÁFICA .....</b>	<b>14</b>
2.1 ÁREAS DE RISCO AMBIENTAL .....	14
2.2 SENSORIAMENTO REMOTO .....	16
2.3 PROCESSAMENTO DIGITAL DE IMAGEM .....	17
2.3.1 Registro.....	17
2.3.2 Mosaico .....	18
2.3.3 Classificação Supervisionada .....	18
2.3.3.1 Maxver.....	19
2.3.4 Validação dos Dados .....	20
2.3.5 Modelo Digital de Terreno .....	23
2.3.6 ASTER GDEM (Global Digital Elevation Model) .....	23
2.3.7 Declividade.....	24
2.4 PARÂMETROS DE IDENTIFICAÇÃO E CARACTERIZAÇÃO DE ÁREAS DE RISCO .....	25
2.4.1 Precipitação .....	25
2.4.2 Tipo de Cobertura Vegetal .....	25
2.4.3 Geomorfologia.....	26
2.4.4 Ação Antrópica.....	27
2.4.5 Solo.....	28
2.4.6 Hidrografia .....	28
2.5 REDES NEURAIS ARTIFICIAIS (RNA).....	29
<b>3 MATERIAL E MÉTODOS .....</b>	<b>32</b>
3.1 ÁREA DE ESTUDO .....	32
3.1.1 Área de Aprendizado da RNA.....	32
3.1.2 Área de Simulação do Aprendizado da RNA.....	33
3.2 AQUISIÇÃO DAS INFORMAÇÕES .....	34
3.3 PROCESSAMENTO DOS DADOS.....	35
3.4 INTEGRAÇÃO DOS DADOS NA REDE NEURAL ARTIFICIAL .....	37
3.5 AVALIAÇÃO DOS RESULTADOS .....	40
<b>4 RESULTADOS E DISCUSSÃO .....</b>	<b>41</b>
4.1 MATERIAIS USADOS PARA AQUISIÇÃO DE INFORMAÇÃO NA REGIÃO DE OCORRÊNCIA DE DESLIZAMENTO .....	41
4.1.1 Ocorrência de Deslizamento.....	41
4.1.2 Informação Espectral.....	42
4.1.3 Uso e Ocupação do Solo.....	43
4.1.4 Classe de Solo.....	44
4.1.5 Informação de Declividade.....	45
4.1.6 Direção do Fluxo .....	46
4.1.7 Comprimento do Fluxo.....	47
4.1.8 Hidrografia .....	48
4.2 MATERIAIS USADOS PARA AQUISIÇÃO DE INFORMAÇÃO EM DOIS VIZINHOS .....	49
4.2.1 Informação Espectral.....	49

4.2.2 Uso e Ocupação do Solo.....	50
4.2.3 Classe de Solo.....	51
4.2.4 Informação de Declividade.....	51
4.2.5 Direção do Fluxo .....	52
4.2.6 Comprimento do Fluxo.....	53
4.2.7 Hidrografia .....	54
4.3 INTEGRAÇÃO DOS DADOS NA REDE NEURAL ARTIFICIAL .....	55
4.3.1 Treinamento da RNA.....	55
4.3.2 Simulação da RNA .....	57
4.4 AVALIAÇÕES DOS RESULTADOS .....	61
<b>CONSIDERAÇÕES FINAIS.....</b>	<b>63</b>
<b>REFERÊNCIAS .....</b>	<b>65</b>

## 1 INTRODUÇÃO

Fenômenos naturais como tornados, terremotos, tsunamis, deslizamentos, ocorrem no mundo inteiro e a todo o momento. Alguns desses fenômenos são imperceptíveis e outros avassaladores, levando a condenação de diversas vidas por falta de uma metodologia de prevenção. Esses fenômenos se tornam desastres naturais quando acontecem em áreas habitadas ou exploradas pelo ser humano, além de atingir a fauna e flora local devido a essa falta de planejamento.

No mundo, deslizamentos de terra vêm afetando a população mundial. No Brasil não é diferente. Os anos de 2010 e de 2011 foram marcados por desmoronamentos de terra tanto em áreas urbanas quanto em áreas rurais, onde as estradas tornaram-se intransitáveis devido a bloqueios. Vidas foram interrompidas e famílias foram isoladas como consequência desses deslizamentos. O estado do Rio de Janeiro iniciou o ano de 2011 sofrendo com a consequência da falta de planejamento, onde as suas regiões montanhosas sofreram perdas irreparáveis, tanto no que diz respeito a vidas, quanto no que tange a própria economia.

Geralmente nos casos de desastres, a prevenção e proteção da população não são realizadas de forma eficiente, e milhares de vidas são perdidas em pouquíssimo tempo. Além disso, cidades inteiras podem ter a sua infra-estrutura bastante prejudicada e seus habitantes tendo que recomeçar suas vidas do zero. Nesse sentido, essas cidades podem levar anos para recompor uma situação que poderia perfeitamente ter sido prevenida e planejada, administrando essas situações para que ocorram respostas rápidas aos possíveis e previsíveis desmoronamentos.

Normalmente os efeitos desses desastres apresentam padrões quanto á climatologia, geologia, hidrologia. Uma rede neural artificial (RNA) é caracterizada por distinguir classes em regiões que contém características padronizadas. Essa técnica consiste em realizar um treinamento com padrões de diferentes fontes, sem conhecimento a priori do modelo, após simular esse aprendizado a toda região experimental desejada. Logo buscando-se prevenir e amenizar os efeitos desses desastres, a utilização da RNA para integração e detecção de padrão torna-se uma alternativa interessante.

Os SIG's (Sistema de Informação Geográfica) são “ferramentas para recolher, armazenar, aceder, transformar e visualizar dados espaciais do mundo real”, construídos com objetivo de servir de fonte de informação para o “planejamento e controle de zonas agrícolas, em especial as florestas, aproveitamento de solos, gestão de redes hídricas e exploração

mineira”, entre outros temas na área ambiental, além de trabalhos na área de sociologia e economia (ABRANTES, 1998, p. 22). Podem ser construídos a partir de uma simples coleta e digitalização de dados, atribuindo a esses sua localização num plano de informação, ou implementados a partir de diversas fontes de dados como, por exemplo, levantamentos aéreos (perfilamento a laser, fotografia), satélite (imagens orbitais, radar), etc.

Sobretudo, a utilização de programas SIG, tendo em mãos uma miscelânea de dados de uma mesma localidade, pode gerar inúmeros produtos como índice de erodibilidade, gerenciamento das áreas para o cultivo agrícola e florestal, planejamento e construções de estradas, tendo como base: mapas hipsométricos (curvas de nível), de declividade (*slope*), orientação (aspecto), e a partir da combinação desses, com mapas de erodibilidade, rampas homogêneas, entre outros, etc. Com o objetivo de realizar essa integração de forma automática, ou melhor, semi-automática das informações obtidas a partir dos padrões cartográficos, utilizam-se técnicas da área de inteligência artificial, como a rede neural artificial para identificar as áreas de risco de deslizamento.

## 1.2 OBJETIVO

### 1.2.1 Objetivo Geral

O presente trabalho possui o objetivo de integrar dados de diferentes fontes usando a rede neural artificial para verificar se a mesma é capaz de aprender os padrões existentes nas áreas de risco de deslizamentos, e utilizar do aprendizado para verificar se existem destes padrões na mesma área de ocorrência e em Dois Vizinhos/Paraná.

### 1.2.2 Objetivos Específicos

- 1) Realizar o estado da arte quanto a áreas de risco ambiental no sudoeste do Paraná e variáveis que influenciem na ocorrência.
- 2) Gerar os mapas de declividade, uso e ocupação do solo, classe de solo, imagem espectral, comprimento do fluxo, direção do fluxo e hidrografia da região de ocorrência de deslizamento e de Dois Vizinhos.
- 3) Preparar a amostragem dos dados de diferentes fontes para o treinamento da RNA.
- 4) Analisar diferentes arquiteturas da RNA, buscando o melhor resultado de treinamento
- 5) Simulação dos padrões encontrados para Dois Vizinhos e para a mesma área de deslizamento.

## 2 REVISÃO BIBLIOGRÁFICA

### 2.1 ÁREAS DE RISCO AMBIENTAL

Áreas de risco podem ser definidas como locais impróprios para atividades antrópicas, pois estão sujeitas a desastres naturais. Geralmente as encostas de morros e as beiras de rios são os locais mais suscetíveis a desastres naturais. A Defesa Civil é a instituição responsável pelo acompanhamento das áreas de risco (CASTRO; PEIXOTO; RIO 2005, p.12-13).

Áreas de risco natural são o resultado da interação dos eventos naturais com as atividades antrópicas, sendo necessário o estudo de tais atividades para a compreensão das áreas de risco (ANEAS DE CASTRO, 2000, p. 2).

Um dos eventos naturais que podem vir a ocorrer são os escorregamentos. De acordo com Selby (1993, p. 128) escorregamento é o movimento gravitacional de solo, rocha e vegetação encosta abaixo. Serve de sinal de alerta para a população e evidencia a movimentação do solo a inclinação de postes, árvores, trincas na parede e chão.

Na literatura podemos encontrar alguns trabalhos que pesquisaram sobre risco de deslizamento como os citados a seguir.

Dias e Herrmann (2002, p. 57-72) com o objetivo de discutir a suscetibilidade a deslizamento em áreas ocupadas realizaram o estudo no bairro Saco Grande na cidade de Florianópolis. A metodologia adotada para obter o mapa de suscetibilidade foi o cruzamento dos mapas de: declividade, geomorfológico, mapa de forma das encostas e de uso da terra no software IDRISI. Inicialmente definiram algumas regras para a combinação dos mapas para chegar às classes da intensidade da suscetibilidade. Partindo do princípio que áreas ocupadas ou desmatadas, com declividade acentuada, encostas retilíneas e alto grau de dissecação são onde existe maior perigo, foram definidas situações intermediárias a partir disso. Os resultados encontrados pelos autores foram que 47,3% da área fora pertencente à classe de suscetibilidade nula, juntamente com área sujeita a enchente. Áreas com suscetibilidade alta e muito alta somam 17,82% e suscetibilidade moderada representando 34,84%.

Vanacôr (2006, p. 9-117) realizou uma investigação sobre suscetibilidade a movimentos de massa combinando técnicas de Sensoriamento Remoto (SR), Sistema de Informação Geográfica (SIG) e banco de dados. Como área de estudo se teve a região



nordeste do estado do Rio Grande do Sul caracterizada como relevo montanhoso, encostas íngremes e precipitação bem distribuída. Para compor o mapa de suscetibilidade foram cruzadas informações sobre a topografia, geológico-geotécnicos e antrópicos obtidas a partir de imagens do sensor ASTER, fotografias aéreas, coleta a campo comparando com o deslizamento ocorrido em 2000 e mapas temáticos. A partir dessas imagens aplicou técnicas de interpretação e processamento de imagens, realizou análise geográfica e espacial para identificar as áreas de risco. A metodologia adotada pelo autor mostrou-se eficiente apontando características compatíveis ao ocorrido em 2000.

Francisco (1996, p. 197-209) apresentou uma metodologia de mapeamento de áreas de risco a partir do uso de SIG. Definiu como área de estudo o Parque nacional da Tijuca (RJ) e áreas de entorno. A metodologia adotada foi resultante de consultas de ocorrências de deslizamentos de massa ocorridos. Foram definidas as variáveis ambientais que influenciam na caracterização de áreas de risco (altimetria, declividade, orientação de vertentes, pedologia e litologia) e pesos para cada variável de acordo com seu grau de importância. O mapa final foi dividido em cinco classes de acordo com o grau de risco que representavam.

Dias (2006, p. 1-67) com o objetivo de identificar áreas com suscetibilidade à ocorrência de deslizamentos de terra em uma área da cidade de Salvador (BA) propôs a utilização de bases cartográficas, modelo numérico do terreno (MNT) e declividade para assim realizar uma modelagem matemática tendo como base a teoria dos taludes infinitos. Após avaliar a suscetibilidade ao deslizamento de terra, foi realizado o cálculo do fator de segurança (FS) para avaliar a estabilidade da encosta e posteriormente realizou visita a campo para analisar os pontos suscetíveis. Os modelos matemáticos permitiram que diversas simulações fossem efetuadas, demonstrando que as condições de solo da área atual representam uma classificação de zona de risco baixa.

Monguilhott (2008, p. 13-107) teve como objetivo de gerar através de técnicas de geoprocessamento um mapa de vulnerabilidade de ocorrência de deslizamento na rodovia RS/486 a então denominada Rota do Sol. Com o uso de programas específicos foram analisadas as variáveis como uso do solo, geomorfologia, geologia, modelo digital de elevação (MDE), declividade e índices de vegetação NDVI. O autor atribuiu pesos específicos para cada variável analisada em função do grau de importância, as variáveis foram submetidas ao Processo Analítico Hierárquico (AHP) disponível do software ArcGis. O autor concluiu que a técnica empregada obteve resposta significativa para a determinação de áreas suscetíveis a deslizamentos com forte relação com os pontos críticos analisados em campo.

Meirelles e Reis (2007, p. 1-14) realizaram um diagnóstico sobre áreas de risco natural associadas à precipitação no município de Betim/MG, através de estudo de caso nos períodos chuvosos de 2006-2007 e 2007-2008. A identificação das áreas de risco de deslizamentos foi realizada através da correlação das variáveis declividade e uso do solo e cruzamento do mapa de ocorrência de deslizamento disponibilizado pela Defesa Civil, onde para interpolação dos dados foram atribuídos pesos para as classes declividade e uso da terra. Os autores concluíram que o resultado não foi totalmente satisfatório, para tanto seria necessário avaliar mais fatores, pois a precipitação em alguns locais coincidiu com deslizamentos e em outros não.

Xavier e Berkenbrock (2005, p. 935-947) estudaram sobre os riscos de escorregamentos na área urbana do município de Blumenau (SC). A metodologia utilizada foi desenvolvida a partir do que foi feito por Augusto Filho (1992). Foram utilizados mapas topográficos e aerofotos. A partir da fotointerpretação dos mapas foram identificados na área de estudo quatro graus de risco de escorregamento: muito alto, alto, médio e baixo. Isso foi baseado no documento estabelecido pelo Ministério das cidades, nos trabalhos da prefeitura de São Paulo e UNESP. Os autores concluíram que as causas dos deslizamentos estão relacionadas à redução a resistência por intemperismo, mudança na geometria do sistema, erosão retrogressiva e rebaixamento do lençol freático.

Silva (2008, p. 1-102) criou um modelo para fornecer previsão qualitativa de risco de escorregamento através da utilização da lógica nebulosa (Fuzzy). Para tal objetivo estudou os fatores envolvidos na instabilidade das encostas e a forma como os mesmos se interrelacionam. Como experiência para a criação do modelo utilizou o banco de dados da cidade do Rio de Janeiro. Silva destaca a potencialidade da lógica nebulosa para este tipo de aplicação, apresentando-se como uma ferramenta capaz de auxiliar na detecção de áreas de risco.

## 2.2 SENSORIAMENTO REMOTO

De acordo com Novo (2008, p. 4), Sensoriamento Remoto é a utilização conjunta de modernos sensores, equipamentos para processamento e transmissão de dados, aeronaves, espaçonaves etc, com o objetivo de estudar o ambiente terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias componentes do

planeta Terra em suas mais diversas manifestações. Os sensores são os equipamentos capazes de coletar energia proveniente de um objeto, convertê-la em sinal passível de ser registrado e apresentá-lo em forma adequada à extração de informações.

O sensoriamento remoto visto como sistema de aquisição de informações pode ser subdividido em dois subsistemas, segundo Novo (2008, p. 9): 1) subsistema de coleta de dados e 2) subsistema de análise de dados. Para que o sistema de coleta de dados funcione é necessário que sejam preenchidas algumas condições: a) existência de fonte de radiação; b) propagação de radiação pela atmosfera; c) incidência da radiação sobre a superfície terrestre; d) ocorrência de interações entre a radiação e os objetos da superfície; e) produção de radiação que retorna ao sensor após propagar-se pela atmosfera. O que chega ao sensor é a intensidade de energia que posteriormente se transforma em um sinal passível de interpretação. As interpretações compõem os sistemas de análise de dados que incluem o processamento fotográfico, o processamento eletrônico do sinal, a modelagem etc. Esta análise permite que dados de reflectância, por exemplo da cana-de-açúcar, integrem modelos de produtividade.

Segundo Marcelino (2003, p. 33-68), com as inúmeras aplicações possíveis através das técnicas de sensoriamento remoto e SIG é possível identificar, de forma rápida, grandes áreas de risco, apenas obtendo informações e mapas de áreas que ocorreram desastres naturais.

## 2.3 PROCESSAMENTO DIGITAL DE IMAGEM

### 2.3.1 Registro

O registro de imagem é o processo no qual é relacionado uma imagem orbital a um sistema cartográfico conhecido. Segundo Cartwright (2007, p. 1), o root-mean-square error (RMSE) ou erro médio quadrático (RMS) é uma medida muito utilizada para medição da acurácia entre valores estimados por um modelo e valores reais, sendo utilizado para avaliar o registro de imagem. O mesmo autor analisa a diferença entre esses valores, os quais são chamados de resíduos, e o RMS tem a capacidade de agregar os mesmos em um único

indicador. Pesquisas realizadas pelo INPE apontam que o erro de registro para áreas urbanas não deve ultrapassar de 0,5 píxeis, e para áreas florestais não deve ultrapassar 3 píxeis.

### 2.3.2 Mosaico

Processo de união de imagens com base na localização espacial. Para sua realização são coletados pontos de controle comuns entre as imagens e, através de processos de rotação e translação as imagens são unidas (BAGLI, 2005, p. 11).

### 2.3.3 Classificação Supervisionada

Segundo NOVO (2008, p. 292), a classificação supervisionada pode ser entendida como o processo no qual amostra conhecida de um conjunto de classes é utilizado para classificar pixels de identidade desconhecida. Com este processo, o analista identifica na imagem as classes de informação de seu interesse e separa as regiões que melhor representem estas classes. Dentro destas regiões ele separa áreas de treinamento que contêm os pixels que serão usados como representantes da classe. A partir destes pixels são extraídas determinadas características das classes, que serão usadas para a classificação dos demais pixels.

Segundo Campbell (1996, p. 359), o processo de classificação supervisionada apresenta vantagens e desvantagens em relação à classificação não-supervisionada.

Onde as principais vantagens são: a) O analista tem maior controle sobre o processo (pode escolher o número e o tipo de classes, as regiões de amostragem e o número de amostras). Esta característica é importante principalmente quando a classificação visa a um objetivo específico; b) a classificação supervisionada é balizada pelas classes pré-definidas pelo analista, desta forma, não é necessário concatenar a imagem classificada com as classes de interesse; e c) o analista tem condições de identificar possíveis imprecisões graves pela análise das áreas de treinamento.

As principais desvantagens são: a) O analista impõe uma determinada estrutura de classificação aos dados, através da definição prévia das classes de informação. Estas classes podem não corresponder às classes reais existentes na cena imageada, ou não ser separáveis

no espaço n-dimensional; e b) As áreas de treinamento selecionadas podem não apresentar todas as características das classes que representam. Esta característica pode ter muita influência, principalmente quando a área a ser classificada é grande, complexa ou inacessível.

A classificação de grupos de indivíduos pode ser supervisionada ou não supervisionada. Na classificação supervisionada é conhecida a classe e o padrão na amostra da mesma que foi gerada. Assim o classificador é treinado para realizar a mesma operação correta para novas amostras analisadas. Na realização da classificação não supervisionada os padrões de treino não se encontram classificados como na classificação supervisionada, assim os algoritmos têm que encontrar uma estrutura nos dados que possa permitir dividi-los em grupos. Já que se têm menos informações disponíveis, a classificação é menos precisa do que a obtida com os métodos supervisionados, contudo, esta é a única solução possível para problemas em que não se dispõe de informação acerca dos grupos que geraram os dados (REBOUÇAS; SOUSA; PIRES, 2009, p. 4).

Bernardes et al. (2007, p. 2) cita que a classificação supervisionada se baseia num conjunto de amostras usadas para o treinamento do classificador. Portanto existe a necessidade de observações de campo na data da passagem do satélite ou conhecimentos de fotointerpretação que permitam o reconhecimento dos padrões de uso da terra. Quando não for possível definir áreas representativas para o treinamento, podem ser utilizados algoritmos baseados em regras estatísticas capazes de fazer o reconhecimento das classes presentes na imagem. Neste caso a classificação é dita não supervisionada.

Blaschke et al. (2006, p. 211) ressalta que muitos aspectos da informação em estudo não podem ser obtidos somente com base na informação que se concentra nos pixels, mas sim a vizinhança dos pixels e no contexto dos objetos de interesse. Os algoritmos denominados classificadores por região utilizam informação espectral de cada pixel e a informação espacial que envolve uma relação entre os pixels e seus vizinhos. O processo que ocorre a divisão de imagens em regiões, aglomerando conjunto de pixels homogêneos que apresentam relação com seus vizinhos é denominado segmentação e deve ser executado antes da classificação.

#### 2.3.3.1 Maxver

Maxver é a técnica classificação supervisionada mais popular para tratamento de dados satélites. Este método é baseado no princípio de que a classificação errada de um pixel

particular não tem mais significado do que a classificação incorreta de qualquer outro pixel na imagem (RICHARDS, 2013, p. 250). O usuário determina a significância nos erros de atributos especificados para uma classe em comparação a outras.

A eficácia do Maxver depende, principalmente, de uma precisão razoável da estimativa do vetor médio e da matriz de covariância de toda classe espectral. Isso depende da quantidade de pixels incluídos nas amostras de treinamento. O resultado do Maxver é tanto melhor quanto maior o número de pixels numa amostra de treinamento para implementá-los na matriz de covariância (MOREIRA, 2005, p. 287).

Nas classificações em que se usa o algoritmo Maxver, cada classe é determinada por um modelo de classes gaussiano e multivariado, capaz de descrever a distribuição das classes no espaço de atributos. Este modelo leva em conta as extensões de dados em direções espectrais determinadas. No espaço RGB, elipsóides concêntricas de equiprobabilidade, cuja localização, forma e tamanho refletem a média variância a covariância da classe, determinam a probabilidade do pixel pertencer à classe, porém considera-se que o método Maxver deve ser aplicado quando o analista conhece bem a imagem a ser classificada, para que possa definir classes que seja representativa. O método Maxver utilizado nesse processo é tido como uma classificação pontual, baseada no valor radiométrico do pixel e nos parâmetros da distribuição Gaussiana de cada uma das classes de treinamento. O mapa obtido por esse classificador, em geral, tem uma aparência ruidosa, visto que o contexto espacial não é considerado (TSO; MATHER, 2001, p. 58).

No intuito de solucionar essa questão do contexto espacial, é realizado um treinamento do sistema no qual são determinadas, por meio de amostras, características de cada classe. Usa-se como área de treinamento uma região ou algumas regiões da imagem segmentada, já que estas anteriormente determinaram regiões homogêneas, segundo o critério de semelhança utilizado (TSO; MATHER, 2001, p. 58).

#### 2.3.4 Validação dos Dados

A validação da classificação, ou seja, o quanto a imagem classificada pelo algoritmo representa a realidade, pode ser realizada de forma qualitativa ou quantitativa. A análise qualitativa se resume na fotointerpretação ou conhecimento prévio de campo. Enquanto a análise quantitativa é determinada pela relação entre a imagem classificada pelo algoritmo com uma imagem de referência (gerada a partir dos dados de campo), calculando-se, de forma

simples, a diferença entre a imagem classificada pelo algoritmo e a imagem referência, resultando na percentagem de acerto geral da classificação sem levar em conta as classes (solo, vegetação, cultura, etc), ou através do cálculo da matriz de erro, a qual produz resultados de exatidão para cada classe temática, índices kappa e exatidão global (RICHARDS, 2013, p. 396).

O uso da análise visual pode ser realizado, segundo Novo (2008, p. 293), baseando-se nas características da imagem como tonalidade/cor, textura, padrão, localização, forma, sombra e tamanho, e através dessas características comparar com chaves de identificação, como a desenvolvida para análise de imagens do satélite RADARSAT. Dessa forma, criam-se metodologias para diferenciação das formas, objetos e feições da superfície terrestre e então sua classificação/validação (NOVO, 2008, p. 293). O conhecimento prévio de campo colabora, e muito, nessa análise visual.

Na análise quantitativa, o método mais utilizado é a partir da utilização de uma matriz de erro, também conhecida como matriz de confusão ou tabela de contingência (FIDALGO, 1995, p. 72). Essa matriz relaciona os dados classificados com os dados de referência, apontando a coincidência para cada classe. O somatório da diagonal principal da matriz de erros multiplicado por 100 e dividido pelo somatório de todas as linhas da matriz (total de pixels) resulta na Exatidão Global em percentagem, ou seja, a percentagem de píxeis que coincidiram na classificação. Enquanto isso, o índice Kappa de Cohen é uma medida que avalia a concordância entre dois avaliadores além do que se é esperado no acaso (COHEN, 1960, p. 42).

Segundo Richards (2013, p. 401) o uso do coeficiente kappa (K), é satisfatório na avaliação da exatidão de uma classificação por utilizar em seu cálculo toda a matriz de confusão, diferente da Exatidão Global que só considera os elementos da diagonal principal da matriz. Na Equação (1), abaixo, é demonstrado o cálculo do índice kappa, onde  $X$  = elemento da matriz de erros;  $R$  = número de categorias presentes na matriz de erros;  $X_{ii}$  = elementos da diagonal principal;  $X_{i+}$  = total da linha para uma dada categoria informacional; e  $X_{+i}$  = total da coluna para uma dada categoria informacional.

$$K = (n \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_i + x_{+i}) / n^2 - \sum_{i=1}^c x_i + x_{+i} \quad (1)$$

O índice kappa varia de 0 a 1, onde 0 significa um total acaso no resultado e 1 significa uma perfeita concordância. De acordo com Landis e Koch (1977, p. 165), a

concordância pode assumir algumas características de acordo com a definição do índice kappa, descritas na Tabela 1 abaixo:

**Tabela 1 - Intervalo de aceitação dos resultados do índice Kappa.**

Índice Kappa (K)	Características
$K < 0,2$	Ruim
$0,2 < K < 0,4$	Fraca
$0,4 < K < 0,6$	Média
$0,6 < K < 0,8$	Boa
$K > 0,8$	Excelente

Fonte: Landis e Koch (1977, p. 165).

A matriz de confusão é uma forma de avaliação para representar a verdade de campo e o resultado gerado pela classificação. A matriz apresenta nas linhas a classe correta e na coluna a classe em que o classificador estimou. Na classificação podem ocorrer os erros de omissão e comissão (CENTENO, 2004, p. 194).

Os erros de omissão são referentes aos pixels que foram omitidos da classe a que realmente pertencem (CENTENO, 2004, p. 195). Na Equação (2) está representada a forma de calcular o índice de omissão, onde,  $SL(i)$  é a soma parcial da linha  $i$  e  $M(i,i)$  corresponde ao elemento da diagonal na linha  $i$ .

$$Eom(i) = (SL(i) - M(i,i) / SL(i)) \quad (2)$$

O erro de inclusão corresponde aos pixels que sendo de outra classe, foram incluídos na classe considerada (CENTENO, 2004, p. 196). Na Equação (3) consta a fórmula para calcular o erro de inclusão, onde  $SC(i)$  corresponde a soma parcial da coluna  $i$  e  $M(i,i)$  é o elemento da diagonal da coluna  $i$ .

$$Ein(i) = (SC(i) - M(i,i) / SC(i)) \quad (3)$$

Os erros de omissão e comissão servem para avaliar o quanto uma classe foi sub ou superestimada. Isso leva ao conceito de exatidão do produtor que é o criador do mapa e exatidão do ponto de vista do usuário (CENTENO, 2004, p. 196).

A exatidão do produtor de acordo com Centeno (2004, p. 196), se refere a quantidade de pixels classificadas corretamente em cada classe como demonstrada na Equação (4).



$$EP = (M(i,i) / SL(i)) * 100 \quad (4)$$

A exatidão do produtor se refere ao total de pixels representados como uma determinada classe na imagem temática e se realmente corresponde a essa classe, a representação consta na Equação (5) (CENTENO, 2004, p. 196).

$$EU = (M(i,i) / SC(i)) * 100 \quad (5)$$

Onde:  $M(i,i)$  é o elemento da diagonal na coluna  $i$  e  $SC(i)$  é a soma parcial da coluna  $i$ .

### 2.3.5 Modelo Digital de Terreno

O modelo digital de terreno (MDT) é caracterizado por ser uma representação matemática tridimensional da superfície terrestre, por meio de uma malha de elevação contínua com coordenadas tridimensionais. A qualidade de um MDT deve representar adequadamente as feições do modelado topográfico, as linhas de cumeada e os talwegues, caracterizando de forma mais fiel possível o terreno (FELGUEIRAS, 2001, p. 1).

### 2.3.6 ASTER GDEM (Global Digital Elevation Model)

O avanço dos satélites orbitais proporcionou aos programas espaciais gerarem modelos globais de elevação, como nas missões SRTM (*Shuttle Radar Topography Mission*) e ASTER GDEM (*Advanced Spaceborne Thermal Emission and Reflection Radiometer e Global Digital Elevation Model*). A missão SRTM gerou dados a partir de dispositivo radar, desenvolvido pela NASA (*National Aeronautics and Space Administration*) e NGA (*National Geospatial-Intelligence Agency*) dos Estados Unidos no ano 2000. Os resultados permitiram a disponibilização gratuita de um modelo digital de elevação (MDE) com boa resolução

espacial de 90 m e 10m de acurácia, das latitudes 60° N à 50° S do globo (ERSDAC, 2011, p. 1).

A missão ASTER GDEM, realizada em 2009 a partir de um consórcio da NASA com o Ministério da Economia, Comércio e Indústria do Japão (METI), decidiu utilizar do sensor ASTER para criar um modelo digital de elevação global de livre acesso a partir de pares estereoscópicos com as bandas 3N e 3B, Nadir e *Backwards*, da faixa do IV próximo (0.78-0,86  $\mu\text{m}$ ). A partir dessa premissa, proporcionou a geração de modelo digital de terreno com 30m de resolução espacial com acurácia de 7 a 14m para praticamente todo o globo, de 83° N à 83° S (ERSDAC, 2011, p. 1).

### 2.3.7 Declividade

Declividade é a diferença de altitude entre dois pontos considerando a distância dos mesmos. Além disso, pode ser descrita em graus, referente ao ângulo observado entre o plano e uma reta que corte os dois pontos analisados e percentuais, quando calcula-se a razão da diferença de altitude e a distância entre os dois pontos. Pode ser calculada utilizando das Equações (6) e (7) abaixo:

$$D^{\circ} = \arctan((h_2 - h_1) / \text{dist}) \quad (6)$$

$$D\% = ((h_2 - h_1) * 100) / \text{dist} \quad (7)$$

onde  $D^{\circ}$  e  $D\%$  são a declividade expressa em graus e percentual, respectivamente,  $h_2$  e  $h_1$  são as altitudes em dois pontos distintos, e  $\text{dist}$  é a distância entre estes pontos.

## 2.4 PARÂMETROS DE IDENTIFICAÇÃO E CARACTERIZAÇÃO DE ÁREAS DE RISCO

### 2.4.1 Precipitação

Durante o período de chuva os desastres naturais como escorregamento, desabamentos e inundações são mais passíveis de ocorrerem, pois diminuem a resistência do solo. Os limites de precipitação causadores de deslizamentos variam de acordo com características de cada região analisada como, geologia, topografia, ocupação e interferência antrópica, dentre outros (TATIZANA et al., 1987, p. 13).

Guerra (1994, p. 35) cita que as medidas pluviométricas fornecem a intensidade aproximada da chuva, e que com precipitação contínua e saturação do solo, a coesão e a resistência do material ao deslizamento diminuem.

Augusto Filho e Virgili (1998, p. 468) ressaltam que a chuva é o principal agente para os deslizamentos, já que os deslizamentos até então ocorridos, estão todos relacionados a altos índices pluviométricos. Para tanto considerado o principal agente de deslizamento, podendo atuar nas seguintes formas:

- a) Erosão subterrânea
- b) Diminuição da coesão
- c) Aumento da pressão hidrostática
- d) Enfraquecimento dos materiais (solo, rocha) pelo intemperismo químico

### 2.4.2 Tipo de Cobertura Vegetal

De acordo com Guidicini e Nieble (1984, p. 102), a atuação da cobertura vegetal na estabilidade de encostas, se dá no sentido de reduzir a intensidade dos agentes climáticos no maciço natural, assim favorecendo a estabilidade das encostas. Segundo Gray (1995, p. 4) a cobertura vegetal apresenta comportamentos diferenciados quanto à estabilidade das encostas, podendo ser favoráveis e desfavoráveis.

Dentre os efeitos favoráveis está a redistribuição da água da chuva nas copas das árvores, o que impede o impacto direto da chuva na superfície do terreno, retardando e diminuindo a quantidade de água que se infiltra no solo. Outro fator favorável é o aumento da resistência do solo devido a ação mecânica produzida por raízes pivotantes e profundas (RICKSON, 1995, p. 105).

Os efeitos desfavoráveis podem ser descritos como: efeito alavanca, que é a força cisalhante transferida pelos troncos das árvores ao terreno, quando suas copas são atingidas por fortes ventos; efeito cunha, originado pela pressão lateral causada pelas raízes ao penetrar em fendas, fissuras e canais de solo ou rocha; e a sobrecarga vertical causada pelo peso das árvores, principalmente em encostas com alta declividade (RICKSON, 1995, p. 105).

De acordo com Santos (2004, p. 93), a vegetação natural constitui o único fator externo inibidor dos escorregamentos e de todas as formas de movimentação superficial dos terrenos, através dos seguintes aspectos:

- impede a ação direta das gotas de chuva no solo através das copas e da serrapilheira;
- impede a ação erosiva das águas de chuva por meio de raízes superficiais e da serrapilheira;
- retém por molhamento de todo o edifício arbóreo parte da água da chuva que chegaria ao solo;
- dilui no tempo o acesso da chuva ao solo;
- retira por absorção, e devolve á atmosfera por evapo-transpiração, parte da água infiltrada no solo;
- agrega, “coesiona” e retém os solos superficiais através de uma malha superficial e subsuperficial de raízes.

#### 2.4.3 Geomorfologia

Geomorfologia é o estudo das formas e processos do relevo e declividade. A drenagem de acordo com Netto (1994, p. 102) tem papel importante na definição das formas do relevo.

Declividade representa a inclinação do relevo em relação ao plano de horizonte. A declividade tem significativa importância nos deslizamentos de massa comprovado pelas leis da mecânica dos solos e das rochas (THOMAS, 1979, p. 4).

A influência da declividade não é simples de ser entendida, Fernandes et al. (2001, p. 58) comprovaram que existe relação da declividade com espessura do solo, foliação metamórfica e fraturas de alívio e tensão para a instabilidade nas encostas.

Cassetti (1991, p. 64) afirma que à medida que o declive ou o gradiente da vertente aumenta, maior será o escoamento superficial, devido a diminuição da infiltração de água no solo.

Fernandes e Amaral (1996, p. 148) citam que em locais com declividade acima de 30° o risco de deslizamento é mais frequente do que em locais com declividade acima de 60°, já que nos locais com declividade maior a camada de solo é menos espessa, sendo constituída pela maior parte em rocha, mas ainda sendo passível de deslizamento principalmente com precipitação elevada.

#### 2.4.4 Ação Antrópica

As atividades antrópicas de uso e ocupação do solo constituem um agente modificador da declividade, acelerando os processos de susceptibilidade ao deslizamento. As principais atividades são através dos cortes de taludes ou aterros e na modificação da cobertura vegetal da encosta (WOLLE, 1988, p. 99).

A modificação da cobertura vegetal acelera o processo geomorfológico de degradação. Esse processo tem ocorrido intensivamente no sudoeste brasileiro, em consequência da agricultura e expansão urbana (WOLLE, 1988, p. 100).

O corte dos taludes para a realização de obras como rodovias também acelera os processos geológicos passíveis de deslizamento (FERNANDES; AMARAL, 1996, p. 80). Além disso, o tráfego de veículos faz com que ocorram vibrações, instabilizando as encostas (GUIDICINI; NIEBLE, 1993, p. 63).

As alterações das atividades antrópicas aumentam o volume de material removido transportado pela água, colaborando para os grandes deslizamentos de massa.

#### 2.4.5 Solo

Os diversos tipos de solos se comportam de maneira distinta com a ação da água e do vento causando erosão, a influência depende das propriedades químicas, biológicas e físicas como textura, estrutura, permeabilidade e densidade (BERTONI; LOMBARDI NETO, 2012, p. 61).

A textura do solo é um dos principais fatores que influenciam na quantidade de solo arrastado pela erosão, pois controla a porosidade e permeabilidade. Grandes partículas de areia resistem ao transporte, solos argilosos resistem á desagregação, sendo as partículas de areia fina e silte as texturas mais suscetíveis á desagregação e transporte (BERTONI; LOMBARDI NETO, 2012, p. 61).

Um solo de textura arenosa possui maior porosidade, proporcionando um rápido escoamento da água, retardando o escoamento superficial, porém normalmente tem baixa proporção de argila, esta que liga as partículas moldando em estruturas resistentes ao deslizamento (BERTONI; LOMBARDI NETO, 2012, p. 61).

Estudo realizado por Caseti (1991, p. 28) mostrou as perdas de terra e água em solo argiloso e arenoso, ocorridas em um período no qual a precipitação média anual foi de 1.300 mm e declives entre 9,5% e 12,8%. Sendo que a maior perda de massa e a menor perda de água ocorreram em solo arenoso, e no solo argiloso houve uma menor perda de massa e maior perda de água, fato esse justificável por ter maior agregação entre as partículas, aumentando a resistência aos processos erosivos e dificultando a infiltração da água.

#### 2.4.6 Hidrografia

As redes hidrográficas e o seu entorno são onde o relevo apresenta diferentes características, o vale não recebe influência apenas do rio, mas também sofre influências morfogênicas, tectônicas e litológicas (CHISTOFOLETTI, 1981, p. 163).

Chistofolletti (1981, p. 280) cita que a partir do século XIX a erosão passou a ser considerada como fator para o modelamento dos vales, podendo ser o modelamento como escavamento, alargamento e encompridamento, em casos onde as vertentes são abruptas, os detritos se movem com a ação da água até a jusante do rio, originando os solos aluviais.

## 2.5 REDES NEURAIS ARTIFICIAIS (RNA)

As Redes Neurais Artificiais (RNA) surgiram na década de 1940 junto com o termo inteligência artificial. Estas foram construídas numa tentativa de simular a estrutura e o funcionamento do cérebro humano em um computador. As RNA também são chamadas de abordagens conexionistas, surgiram como uma alternativa à abordagem simbólica, baseada na lógica (HAYKIN, 2001, p. 26).

Uma RNA pode ser definida, de modo simplificado, como um arranjo de unidades, neurônios interconectados, que trabalham em paralelo para classificar e generalizar dados de entrada em classes de saída (HAYKIN, 2001, p. 27). Quando utilizada como classificador, pode incorporar virtualmente qualquer tipo de dados espacialmente distribuídos. São capazes de realizar buscas, aprender pela experiência, descobrir novos caminhos e soluções para problemas, realizar associações e generalizações, além de aprender as características de um padrão a fim de transformá-la em informação utilizável (FITZ, 2008, p. 22).

A maior diferença entre os métodos estatísticos para com as RNA é que os métodos estatísticos estabelecem hipóteses ou suposições sobre a distribuição ou propriedades dos dados de forma teórica, enquanto as RNA tendem a ser mais úteis em situações práticas por possuir a habilidade de aprender as propriedades da distribuição dos dados apresentados à ela (GONÇALVES et al., 1998, p. 973).


Dessa forma, as RNA possuem uma abordagem não-linear, o que produz resultados mais acurados quando se tratando de dados de padrões complexos, onde para cada problema existem diferentes tipos de arquiteturas, mais adequados. Os tipos de redes variam entre si pela arquitetura e algoritmo de aprendizagem (HAYKIN, 2001, p. 48).

A arquitetura de uma RNA é composta, segundo German e Gahegan (1996 p. 972-973), por camadas, as quais são classificadas em três grupos, demonstradas na Figura 1:

Camada de entrada: onde os padrões, ou seja, os dados são apresentados à rede. O número de neurônios nessa camada é igual ao número de dados que se deseja integrar;

Camadas intermediárias: onde é feita a maior parte do processamento, através das conexões ponderadas, ou seja, podem ser consideradas como extratoras ou moduladoras de características. O número de neurônios nessas camadas é variável e essa variação pode produzir diferentes respostas;

Camada de saída: onde o resultado esperado é apresentado.



**Figura 1 - Estrutura da RNA.**  
**Fonte: ICMC (2012, p. 4).**

No uso de imagens orbitais, quando se utiliza mais de uma camada intermediária, normalmente segue-se um padrão de proporção que é de três camadas primárias para cada uma secundária (BOTELHO, 2004, p. 34).

Os algoritmos de aprendizagem existentes são muitos, como: retro-propagação (backpropagation), contra-propagação, Kohonen, cascade-correlation, ART, adaline e madaline, percéptron, etc. (HAYKIN, 2001, p. 75). Apesar de existir diversos tipos, o algoritmo de retro-propagação é o mais utilizado para o treinamento de redes neurais, quando trata-se de imagens espectrais, sendo em parte, responsável pelo ressurgimento do interesse na área de Redes Neurais Artificiais (BOTELHO; VIEIRA, 2002, p. 2).

O algoritmo de aprendizagem retro-propagação foi desenvolvido em 1974 por Paul Werbos. O funcionamento deste algoritmo parte da introdução da primeira amostra dos parâmetros de uma classe à RNA, onde verifica-se a saída gerada e a compara com a saída esperada, o que resulta num erro. A partir desse erro é modificado/atualizado por uma taxa de aprendizagem que visa diminuir essa discrepância, propagando para trás esse desvio, distribuindo-o para todas as camadas de conexões. O processo é continuado através da apresentação de uma nova amostra a RNA. Dessa forma, quanto mais a RNA treina em cima de uma amostragem, o valor do erro tende a convergir para valores estáveis, e o processo continua até que algum critério de parada seja alcançado. Esses critérios de parada podem ser um limiar de erro ou um número de épocas específico (HAYKIN, 2001, p. 188).

A função de ativação é a função que recebe o somatório do produto das entradas pelos pesos e transforma esse somatório em um resultado o qual é passado como entrada para



um próximo neurônio ou para a saída da rede (HAYKIN, 2001, p. 201). Existem vários tipos de função de ativação, sendo elas: lineares, tangente sigmoidal, logarítmica sigmoidal, etc.

A função logarítmica sigmoidal, representada pela Equação (4), e é uma das funções mais utilizadas (HAYKIN, 2001, p. 202). O intervalo da função varia entre 0 e 1, enquanto a entrada do neurônio varia de negativo até infinito.

$$Y = f(n) = 1/1 + e^{-n} \quad (4)$$

Durante a fase de treinamento da rede, existe um fator que determina seu aprendizado que é a taxa de aprendizagem. Essa é a constante que define o tamanho dos passos para a mudança dos pesos ao redistribuir o erro retropropagado. Baixas taxas de aprendizagem resultam num treinamento lento que aumenta a chance de paradas em “mínimos locais” que impossibilita a chegada até o “mínimo global”, ou seja, o aprendizado é encerrado antes do tempo por chegar em um resultado que parece ser o melhor, mas na verdade não é. Altas taxas de aprendizado resultam em oscilação e até saturação do processo de aprendizado (HAYKIN, 2001, p. 202).

A introdução da constante de momento surge para diminuir essa oscilação durante o aprendizado, proporcionando maior estabilidade à rede. Consiste em uma porção do peso antigo que será repassado para o peso novo, possibilitando a diminuição do tempo de treinamento (HAYKIN, 2001, p. 203).

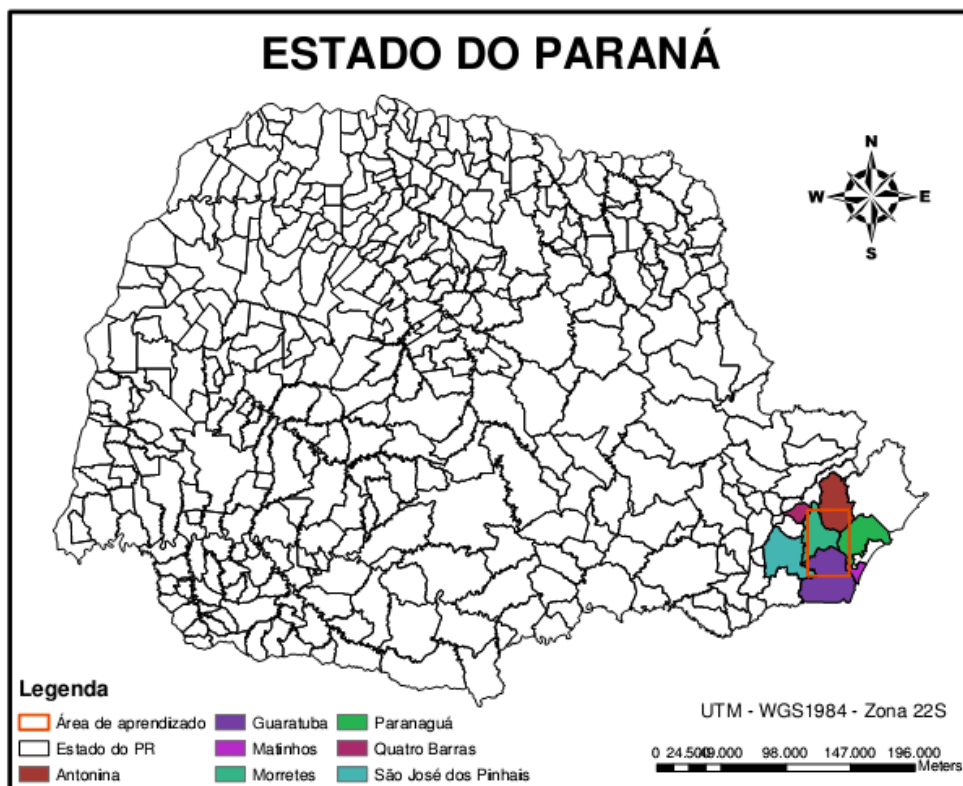
De acordo com Osório e Bittencourt (2000) as redes neurais tem a capacidade de se adaptar e de aprender a realizar determinada tarefa ou seguir determinado comportamento padrão, a partir de um conjunto de exemplos usados para o treinamento. Ou seja, possui uma grande habilidade de aprender através do treinamento, e essa habilidade não deve ser subestimada. Diante disso, muitas vezes existe dificuldade no entendimento de como a RNA chegou a certos resultados, pois a informação fica confinada dentro dos pesos das camadas escondidas (JENSEN, 2007, p. 103).

### 3 MATERIAL E MÉTODOS

#### 3.1 ÁREA DE ESTUDO

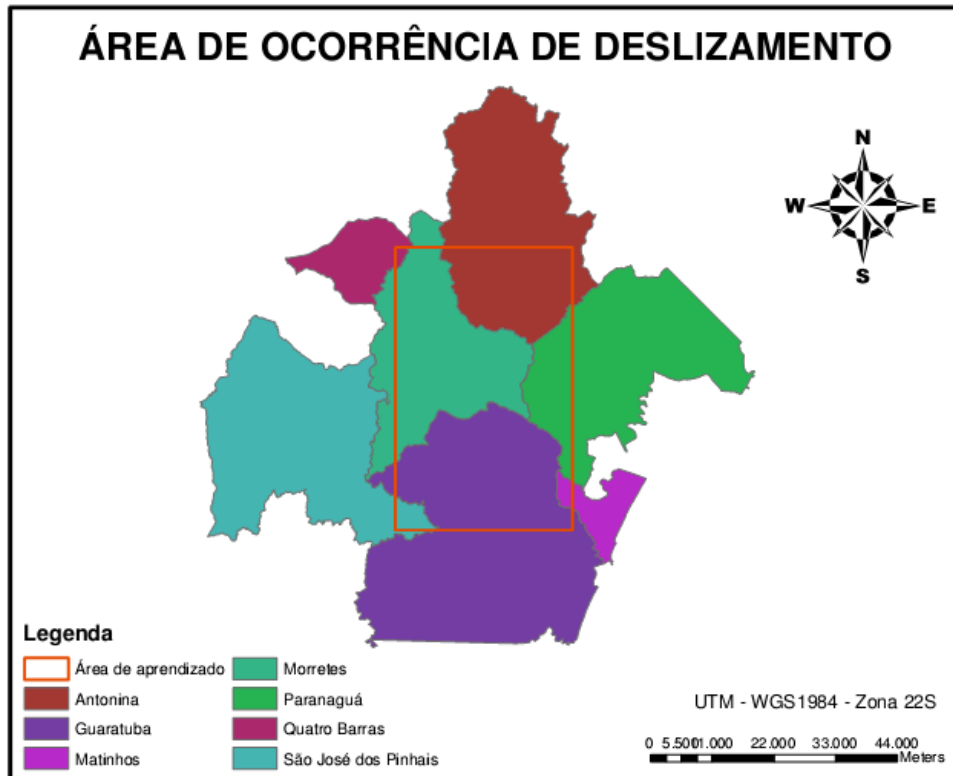
##### 3.1.1 Área de Aprendizado da RNA

Como campo de aprendizado utilizou-se os locais cujas ocorrências de deslizamento foram registradas e mapeadas pela MINEROPAR (2011, p. 1). As ocorrências de deslizamento utilizadas para o treinamento da RNA foram registradas nos municípios de: Antonina, Guaratuba, Matinhos, Morretes, Paranaguá, Quatro Barras e São José dos Pinhais, como demonstrado na Figura 2 e 3.



**Figura 2 - Representação da área de ocorrência de deslizamento utilizada como área de aprendizado da RNA.**

Fonte: A autora (2013).



**Figura 3 - Aproximação dos municípios que fazem parte da área utilizada como aprendizado da RNA.**

**Fonte: A autora (2013).**

### 3.1.2 Área de Simulação do Aprendizado da RNA

Os resultados do aprendizado da RNA na caracterização dos deslizamentos foram aplicados na mesma região que foi usada as amostras para o treinamento da RNA, só que em uma área menor, e no município de Dois Vizinhos que corresponde a região sudoeste do estado do Paraná, como demonstrado na Figura 4.



**Figura 4 - Representação da localização de Dois Vizinhos sobre a imagem do estado do Paraná.**  
**Fonte: A autora (2013).**

### 3.2 AQUISIÇÃO DAS INFORMAÇÕES

A fim de se conhecer as características das áreas com ocorrência de deslizamento utilizou-se o mapeamento contendo as coordenadas geográficas de cada ocorrência de deslizamento no estado do Paraná, levantamento este realizado pela Mineropar (2011, p. 1).

No intuito de caracterizar os deslizamentos utilizou-se de informações referentes ao valor espectral da imagem de satélite (RGB), uso e ocupação do solo, classe de solo, hidrografia, declividade, direção do declive e comprimento do declive.

A informação espectral (RGB) para a área de ocorrência de deslizamento foi extraída do Mosaico Landsat Geocover (2000), com resolução espacial de 14,25 metros, adquiridas gratuitamente por meio do site da NASA (2000, p. 1). Já para Dois Vizinhos foi utilizada imagem do satélite SPOT/5 com resolução espacial de 5 m, datada de 2008, cedida gratuitamente pela AMSOP (Associação de Municípios do Sudoeste do Paraná).

A informação de uso e ocupação do solo foi extraída a partir de uma classificação supervisionada pelo método Maxver para as áreas de estudo.

Para as informações relativas a classe de solo foi usado o mapa de solos do primeiro nível categórico datado de 2006, obtido gratuitamente pela EMBRAPA (2006, p. 1).

Para compor a informação de hidrografia, foi utilizado o arquivo temático denominado rios massa d'água (COPEL, 2011, p. 1; AGUASPARANÁ, 2011, p. 1).

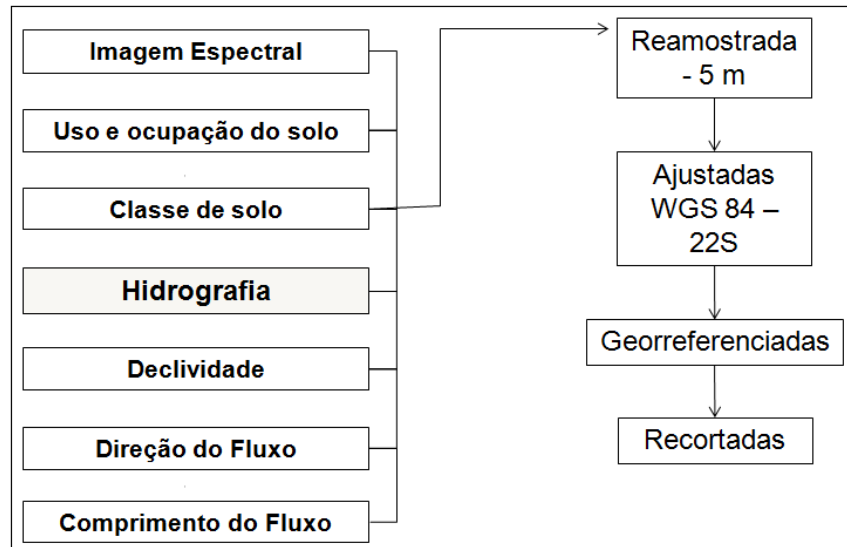
As informações quanto a declividade foi um produto obtido do modelo digital de elevação ASTER GDEM, obtido gratuitamente pela ERSDAC (2009, p. 1), imageamento este realizado em 2009, o DEM foi confeccionado a partir de imagens de pares estereoscópicos com 30 metros de resolução espacial e acurácia de 7 a 14 metros.

A direção de fluxo foi gerada a partir da imagem de declividade e a partir da direção de fluxo, foi confeccionada a informação referente ao comprimento do fluxo.

### 3.3 PROCESSAMENTO DOS DADOS

A imagem de ocorrência de deslizamento e os fatores associados a este evento foram ajustados para a mesma cena de interesse, ou seja, utilizaram-se mapas que cobriram tanto a área de aprendizado e posterior simulação quanto para Dois Vizinhos. Todas as imagens foram projetadas para o mesmo sistema de projeção UTM com o Datum WGS 1984, zona 22 sul, e mosaicadas processo que consiste na união das imagens com base em pontos homólogos, reamostrada - mudança na resolução espacial pelo método de convolução cúbica para resolução espacial de 5 metros e registradas com base em um sistema cartográfico conhecido.

Um resumo dos processamentos a serem realizados estão representados na Figura 5.



**Figura 5 - Processamentos realizados com os mapas.**  
**Fonte: A autora (2013).**

A informação de uso e ocupação do solo foi obtida a partir das imagens multiespectrais, onde foi realizada a classificação supervisionada que é realizada a partir de amostras conhecidas de classes distintas para que o classificador reconheça os demais pixels de identidade desconhecida da imagem. O classificador utilizado foi o Maxver, onde foram definidas classes, sendo: vegetação primária (sendo identificadas áreas de máxima expressão local, sendo áreas que as ações antropicas não afetaram significativamente), vegetação secundária (sendo identificadas áreas resultantes dos processos naturais de sucessão), solo exposto, água e em Dois Vizinhos além destas foi encontrado áreas ocupadas por pastagens, sendo agrupadas junto com a classe de culturas anuais.

O mapa de declividade foi obtido a partir dos dados altimétricos do sensor ASTER GDEM no software Envi 4.7, onde este calcula a declividade levando em consideração a diferença de altitude entre dois pontos em relação a distância dos mesmos.

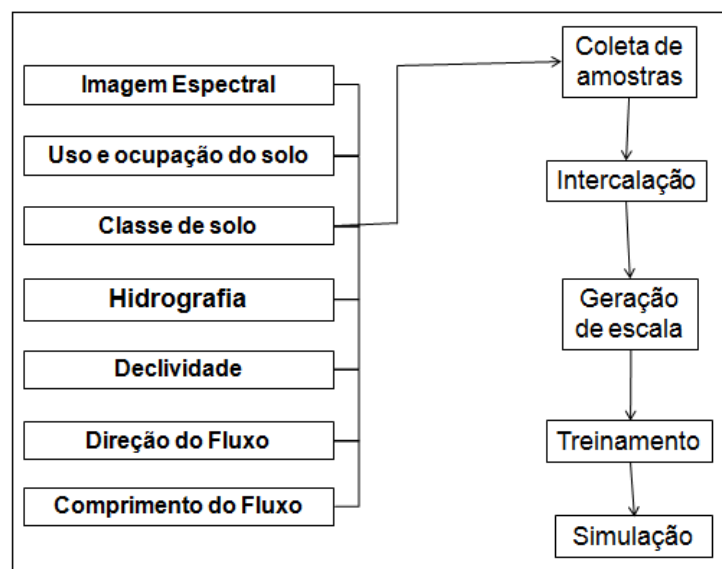
A informação referente a direção de fluxo (Flow Direction) foi gerada a partir da extensão Spatial Analyst do software Argis 10. A direção de fluxo determina a direção de maior declividade de um pixel em relação aos seus 8 pixels vizinhos, este cálculo monta uma grade de pixels com o valor correspondente a direção do escoamento da água (RENNÓ et al. 2008, p. 2).

Com base no arquivo de direção de fluxo foi confeccionado o arquivo de comprimento do fluxo (Flow Accumulation), este que representa a rede de drenagem e contem os valores de acúmulo da água em cada pixel, ou seja, é atribuído o valor

correspondente ao número de pixels que contribuem para que a água chegue até o determinado pixel (MENDES; CIRILO, 2001, p. 259).

### 3.4 INTEGRAÇÃO DOS DADOS NA REDE NEURAL ARTIFICIAL

A integração de dados na RNA se dá pela realização das seguintes etapas: obtenção de amostras, intercalação, normalização das imagens, geração de escala, treinamento da rede e simulação, o fluxograma geral da parte de integração das informações na RNA está disposto na Figura 6.



**Figura 6 - Processamentos realizados.**  
**Fonte: A autora (2013).**

Será utilizado de algoritmos já implementados por Mosar Faria Botelho, Ricardo Dal'agnol da Silva e Mauricio de Souza no software Matlab, contendo rotinas para a obtenção da escala, abertura de imagens e com a RNA propriamente dita.

Foram realizadas várias coletas de amostras sobre a área de ocorrência de deslizamento buscando determinar o número ideal de amostras que representam as variáveis que caracterizam os deslizamentos e para obter o maior acerto durante o aprendizado. A primeira coleta iniciou-se com 84 amostras para representar as duas classes (ocorrência e não ocorrência de deslizamento), porém os mapas de caracterização de deslizamento utilizados

para o processamento era distinto dos realizados neste estudo, chegando a 68% de acertos como constatado por Debastiani et al. (2012, p. 6).

De posse dos mapas correspondentes à área de aprendizado coletaram-se todas as amostras dos locais onde ocorreu deslizamento, totalizando 332.718 amostras, e para a área de não ocorrência foi aleatorizada sobre a imagem a mesma quantidade de pontos (332.718), a justificativa para a aleatorização na classe de não ocorrência foi levando em consideração que nesta classe existe um maior número de pontos. Estas coletas consistiram em capturar o valor digital do pixel de todas as imagens nos determinados pontos espaciais definidos.

Utilizando do arquivo contendo o conjunto de todas as amostras coletadas, para classe de ocorrência e não ocorrência, o que totalizou 665.436 amostras, gerou-se a escala, esta que corresponde a determinação dos valores mínimo e máximo da amostra total para cada parâmetro, a partir da Equação (8) abaixo:

$$E = \frac{1}{(Max - Min)} \quad (8)$$

Na Equação (5), a letra E representa a escala observada para valores de máximo (Max) e mínimo (Min) para cada parâmetro calculado.

Sobre os arquivos correspondentes as informações de coleta, foi novamente coletado aproximadamente 38% dos dados, sendo que foi destinado 8,33% para treinamento e 30% para verificação do aprendizado da RNA. Para se certificar que os arquivos vetores com um ponto por linha, tinham todas as linhas diferentes um do outro, foi utilizado de um algoritmo que percorreu por todas as linhas do arquivo de treinamento e verificou se existia alguma linha com todos os elementos iguais no arquivo de verificação, e quando o mesmo existisse, excluiu-se a linha no arquivo de verificação, garantindo assim arquivos com pontos diferentes em ambos arquivos.

Os arquivos de treino e verificação, empiricamente tiveram suas linhas intercaladas e assim a RNA teve a possibilidade de aprender os padrões do conjunto de informações de forma simultânea.

As informações de diferentes fontes coletadas, ou seja, informação espectral (RGB), uso e ocupação do solo, declividade, hidrografia, direção do declive, comprimento do declive e classe de solo, foram integradas na Rede Neural Artificial (RNA) para que a mesma encontrasse o melhor modelo para os padrões existentes nas áreas de risco.



A arquitetura da RNA utilizada foi a perceptron multi-camadas e algoritmo de aprendizado retro-propagação (*backpropagation*) por ser a mais indicada pelas literaturas quanto utiliza-se de informações em modelos raster.

A Rede Neural Artificial (RNA) teve como dados da camada de entrada as informações de uso e ocupação do solo, informação espectral (RGB), classe de solo, hidrografia, declividade, direção do fluxo e comprimento de fluxo.

Buscando a melhor arquitetura de aprendizado da RNA foi alterado o número de neurônios da camada de entrada, camada intermediária, taxa de aprendizado, momento e número de épocas de forma sucessiva e empírica. A função de ativação usada foi a sigmoideal.

Foi ajustado para que a saída da RNA fosse a ocorrência, podendo ser entre os valores 0 e 1. Sendo que o valor 1 corresponde a locais com ocorrência de deslizamento e valor 0 locais sem ocorrência de deslizamento.

Para verificar o treinamento, o algoritmo implementado foi ajustado para que a RNA classificasse e quantificasse os locais de ocorrência e não ocorrência, ou seja, quando o valor de verificação do aprendizado fosse menor ou igual a 0,4 corresponde aos locais sem ocorrência de deslizamento, quando o resultado fosse maior que 0,6 correspondesse aos locais com ocorrência de deslizamento, e quando o resultado fosse intermediário a estes apresentados, considerado como sendo dúvida da RNA. Para verificação do quão correto foi a saída da RNA, o algoritmo foi ajustado para que fosse somada a percentagem dos acertos ou erros, levando em consideração o valor classificado pela RNA e o valor a qual realmente corresponde.

O treinamento com maior percentagem de acertos foi passado para a simulação. Nessa etapa foi aplicada a simulação em um recorte da mesma área de onde foram extraídas as informações para o treinamento da RNA e para Dois Vizinhos que é uma área diferente da área de treinamento, para que a RNA verificasse e apontasse as áreas possíveis de ocorrer deslizamento.

Na etapa de simulação o algoritmo foi ajustado para que fosse salva uma imagem contendo apenas a classificação da RNA como sendo ocorrência e não ocorrência e outra imagem com os níveis de risco, definidos como sendo: menor que 0,4 para tendência a não ocorrência, maior que 0,4 e menor que 0,5 para incerteza de não ocorrência, maior que 0,5 e menor que 0,6 para incerteza de ocorrência, maior que 0,7 e menor ou igual a 1 para tendência a ocorrência de deslizamento.

### 3.5 AVALIAÇÃO DOS RESULTADOS

A verificação da eficiência da RNA na fase de treinamento foi a partir do ajuste do algoritmo para que fosse somada a percentagem dos acertos ou erros, levando em consideração o valor classificado pela RNA e o valor que a classe realmente corresponde. Nestes resultados foram realizados alguns testes estatísticos de média, desvio padrão e coeficiente de variação.

-Média: É o somatório dos elementos em função do número total de elementos, como demonstra a Equação 9.

$$\bar{X} = \frac{\sum n_i}{n} \quad (9)$$

Onde: n são as amostras.

- Desvio padrão: É a raiz quadrada do somatório da diferença de cada elemento  $x_i$  em relação a média ao quadrado, ou seja, é a raiz quadrada da variância, descrita na Equação 10.

$$S = \sqrt{\sum_1^k \frac{n_i (x_i - \bar{x})^2}{n-1}} \quad (10)$$

Onde: n são as amostras.

- Coeficiente de variação: É a porcentagem da relação entre o desvio padrão e a média, como descrita na Equação 11.

$$CV = \frac{S}{\bar{X}} \quad (11)$$

Onde: S: desvio padrão e X é a média.

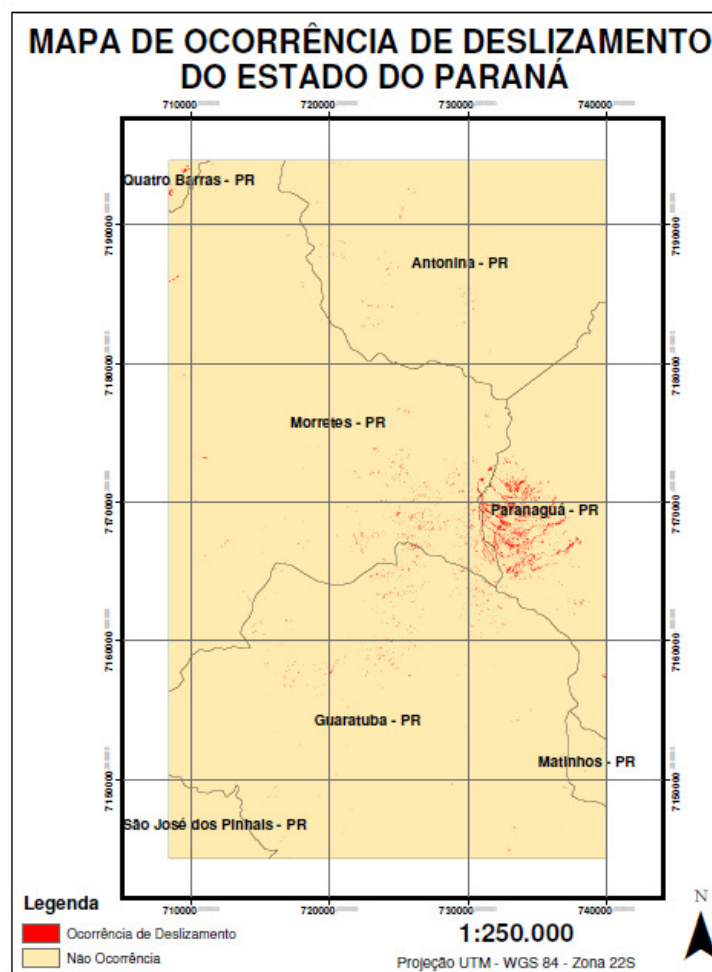
Para verificação da exatidão dos resultados da RNA na fase da simulação, na mesma área utilizada como treinamento, foi calculada a matriz de confusão e determinação do índice kappa e exatidão global. Os índices kappa foram avaliados quanto a aceitação dos resultados proposto pela classificação de Landis e Koch (1977, p. 165).

## 4 RESULTADOS E DISCUSSÃO

### 4.1 MATERIAIS USADOS PARA AQUISIÇÃO DE INFORMAÇÃO NA REGIÃO DE OCORRÊNCIA DE DESLIZAMENTO

#### 4.1.1 Ocorrência de Deslizamento

A imagem das ocorrências de deslizamento gerada a partir dos dados disponibilizados pela Mineropar (2011, p. 1) está disposta na Figura 7 abaixo.



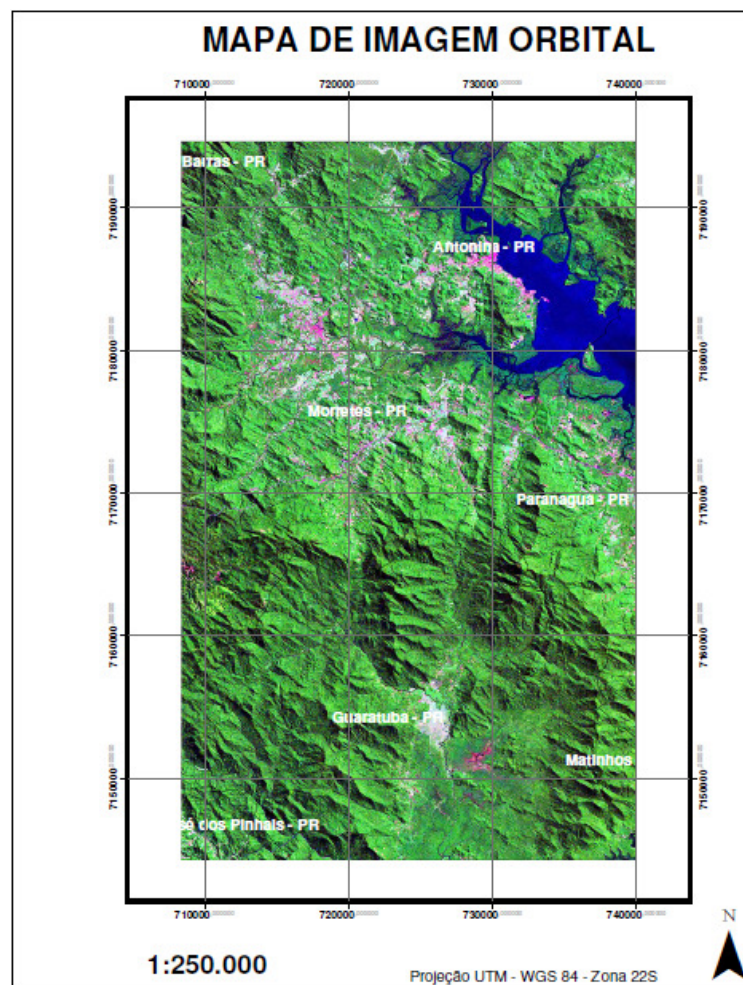
**Figura 7 - Imagem da localização das ocorrências de deslizamento no estado do Paraná.**

**Fonte: Adaptado de Mineropar (2012).**

Na Figura 7, os polígonos representados na cor vermelha são as ocorrências de deslizamento registradas, as ocorrências estão localizadas na região leste, litoral do estado.

#### 4.1.2 Informação Espectral

A imagem espectral da área onde ocorreu deslizamento originaria do projeto Geocover, composta pelas bandas R, G, B está disposta na Figura 8 abaixo.



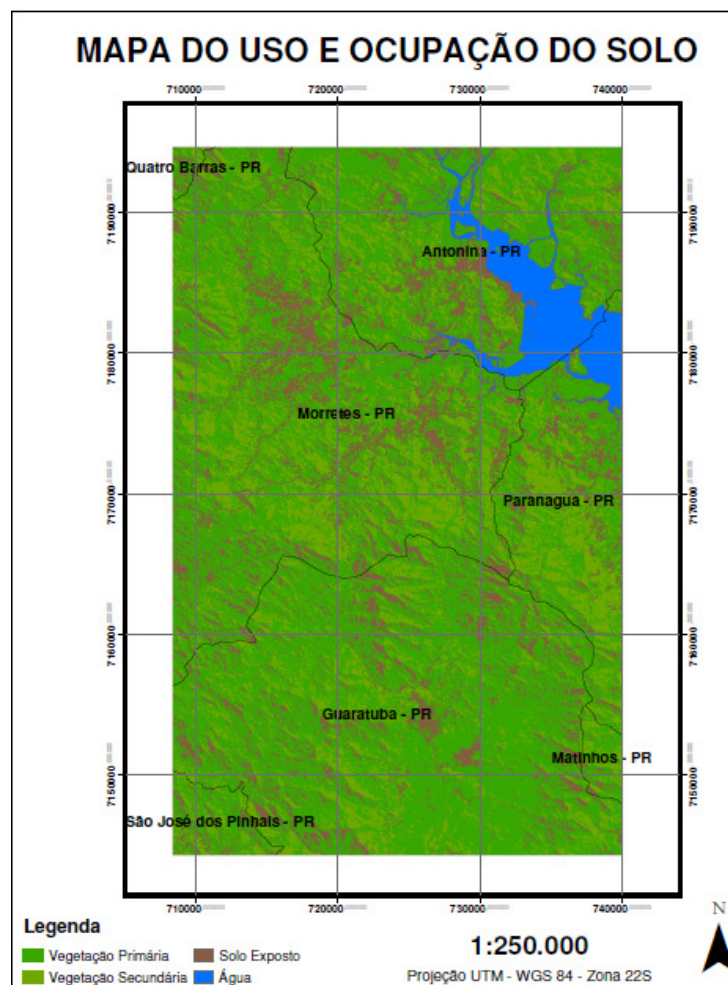
**Figura 8 - Imagem de satélite da região de ocorrência de deslizamento no estado do Paraná.**

**Fonte: Adaptado de NASA (2000).**

É possível observar na parte superior direita da Figura 8 uma extensão do Oceano Atlântico, a vegetação recobre a maior parte da imagem em tom de verde e pode-se observar nos tons de rosa que são áreas de edificações e solo exposto.

#### 4.1.3 Uso e Ocupação do Solo

A imagem gerada através da classificação supervisionada pelo método Maxver está disposta na Figura 9.

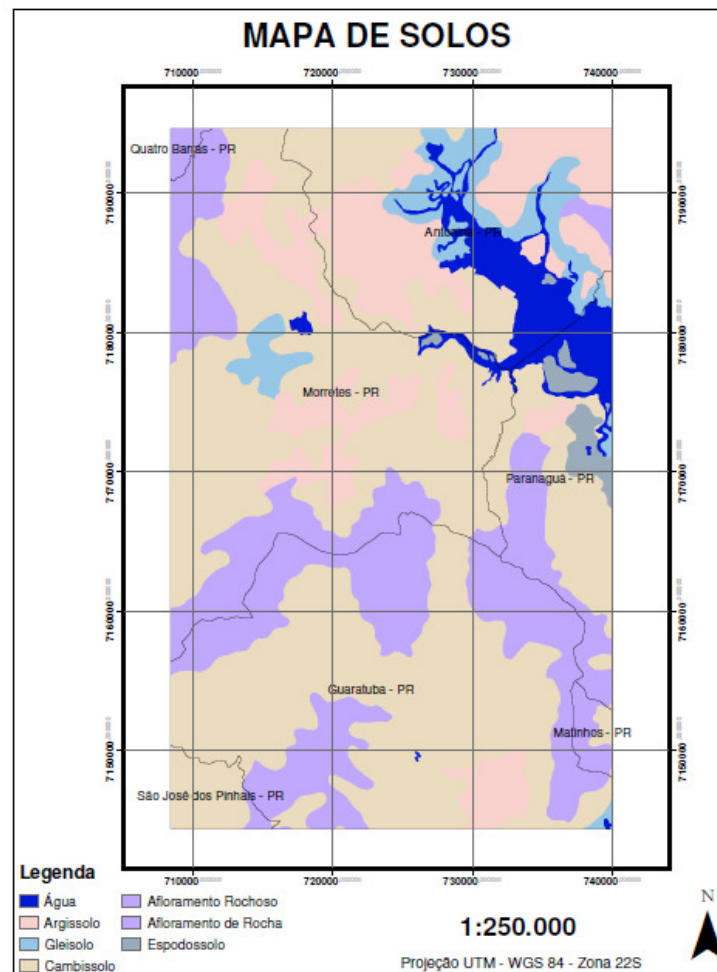


**Figura 9 - Imagem do uso e ocupação do solo na área de treinamento da RNA. Fonte: A Autora (2013).**

Pode-se observar na Figura 9 que representa o uso e ocupação do solo que as classes que mais recobrem a área são a de vegetação primária e secundária.

#### 4.1.4 Classe de Solo

A Figura 10 representa a classificação de solos pela Embrapa (2006, p. 1) na área de ocorrência de deslizamento.



**Figura 10 - Classes de solo na área de treinamento da RNA.  
Fonte: Adaptado da EMBRAPA (2006).**

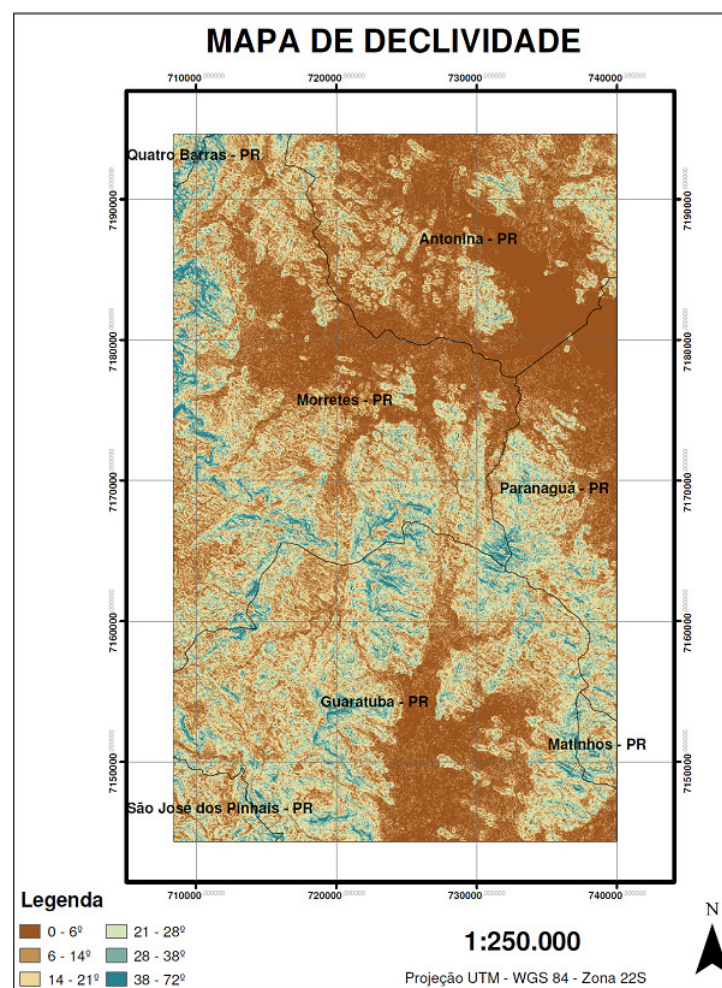
Na Figura 10, estão representadas as seis classes de solo definidas pela EMBRAPA que são encontradas na área utilizada como treinamento da RNA, sendo seis classes de solo e



na cor azul escuro da imagem representa água. Ao se comparar a localização das ocorrências e os tipos de solos, pode-se afirmar que a maioria das ocorrências tem afloramento de rocha como classe de solo seguida da classe de Cambissolo.

#### 4.1.5 Informação de Declividade

Na Figura 11 abaixo está representada a declividade da região de onde ocorreram os deslizamentos no estado, área esta próxima ao litoral, as declividades foram agrupadas em classes para melhor representação.

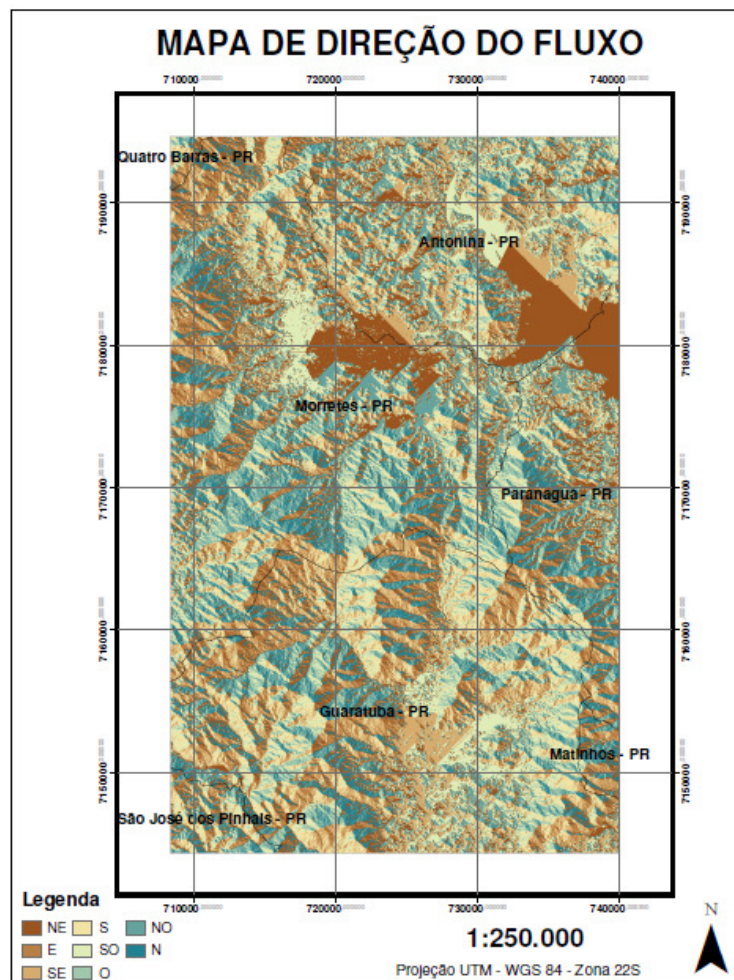


**Figura 11 – Grau de inclinação do terreno próximo ao litoral do estado do Paraná.**  
Fonte: A Autora (2013).

O tom de marrom representa as áreas de declividade menor e a medida que este tende ao azul a sua declividade vai aumentando. Nota-se que a maioria das ocorrências de deslizamento foi em locais de declividade média situadas entre 15° à 30°.

#### 4.1.6 Direção do Fluxo

A informação de direção do fluxo gerada a partir da informação de declividade está exposta na Figura 12.



**Figura 12 – Mapa da direção do fluxo.**

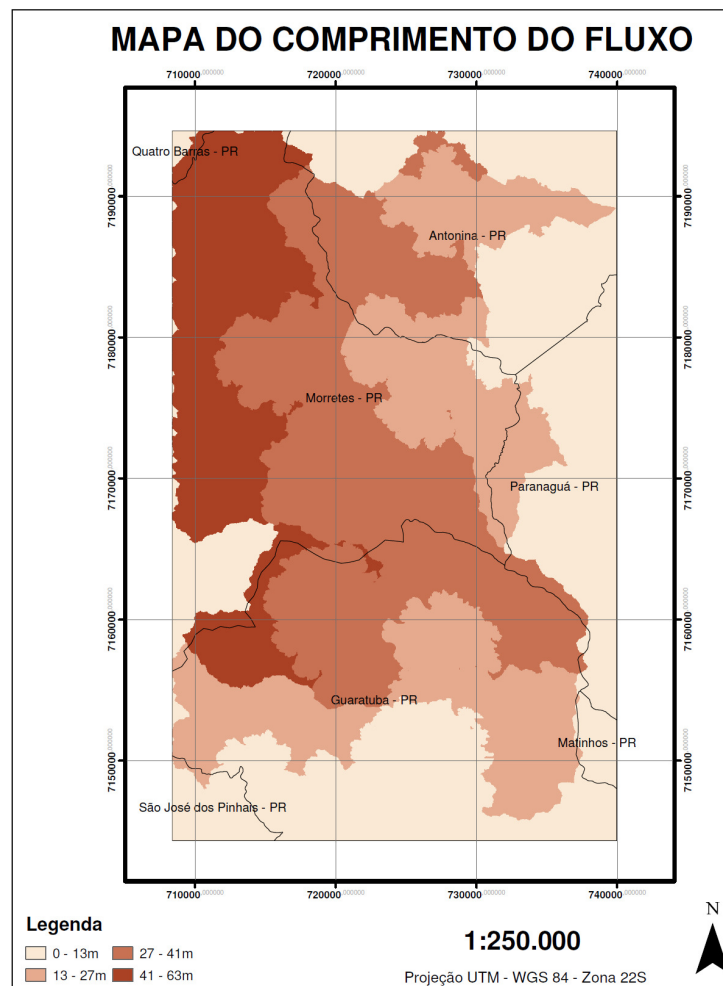
**Fonte: A Autora (2013).**



Pode-se observar na Figura 12 a direção do fluxo para região de ocorrência de deslizamento, as direções do fluxo determinam a direção de escoamento da água.

#### 4.1.7 Comprimento do Fluxo

A informação da direção do fluxo proporcionou a geração do comprimento do fluxo que está localizado na Figura 13.



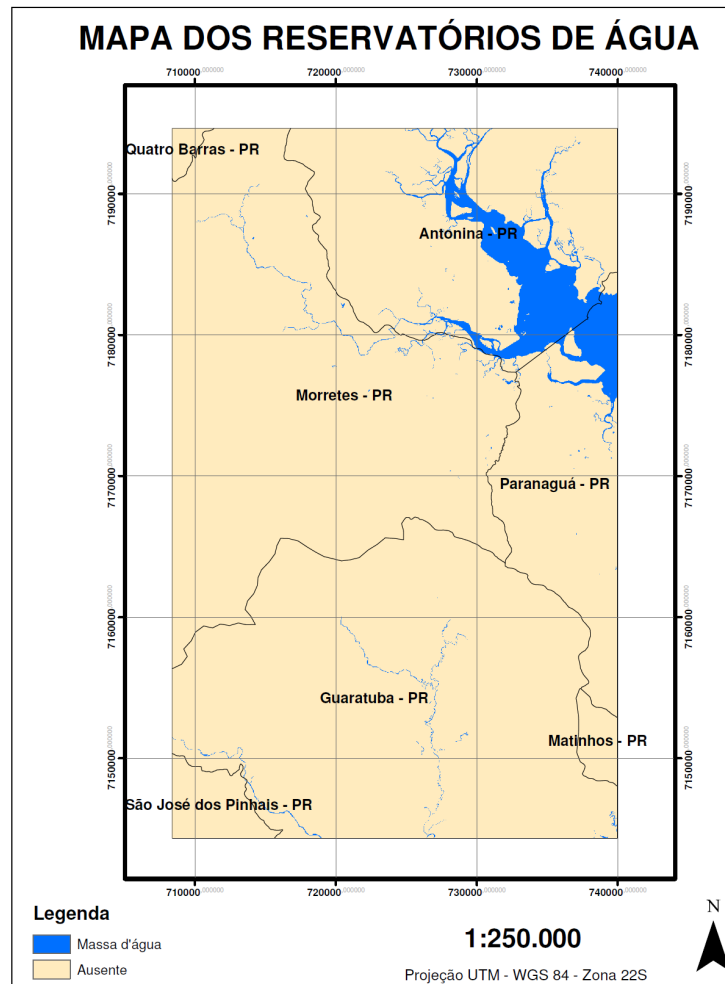
**Figura 13 – Mapa do comprimento do fluxo.**

**Fonte: A Autora (2013).**

Na Figura 13, pode-se observar que as áreas com a cor clara apresentam comprimento de fluxo menor, já as áreas com cores fortes têm comprimento de fluxo maior, ou seja, apresentam área de contribuição para escoamento de água maior.

#### 4.1.8 Hidrografia

A informação de hidrografia utilizada para a área de ocorrência de deslizamento está disposta na Figura 14.



**Figura 14 - Informação de hidrografia.**

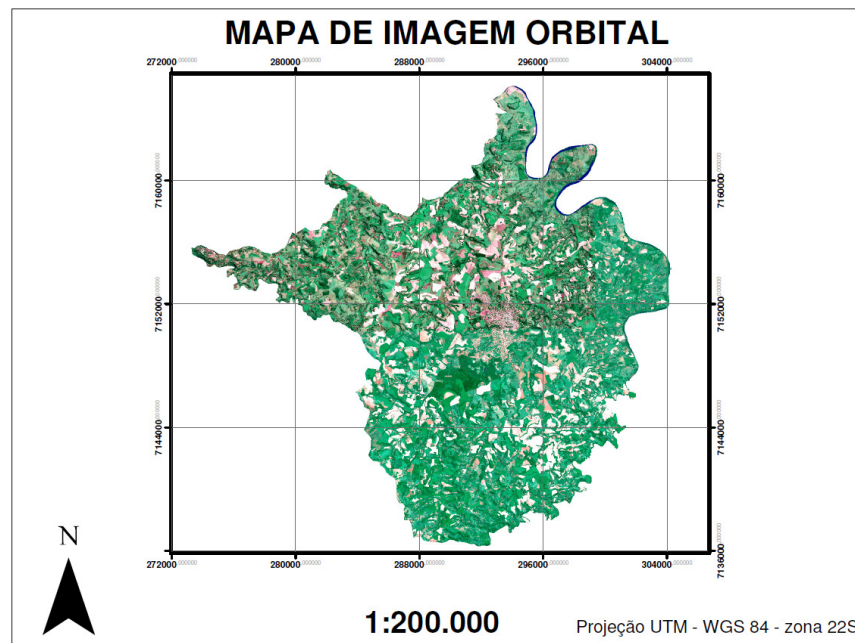
**Fonte: Adaptado de Copel e Águas Paraná (2011).**

Pode-se observar que em locais próximos aos reservatórios de água não ocorrem deslizamentos, devido a estes locais apresentarem também baixa declividade e outros fatores que contribuem.

## 4.2 MATERIAIS USADOS PARA AQUISIÇÃO DE INFORMAÇÃO EM DOIS VIZINHOS

### 4.2.1 Informação Espectral

As informações correspondentes a R, G e B da imagem espectral para Dois Vizinhos está representada na Figura 15.



**Figura 15 - Imagem espectral do município de Dois Vizinhos, esta do satélite SPOT/5, datada de 2008.**

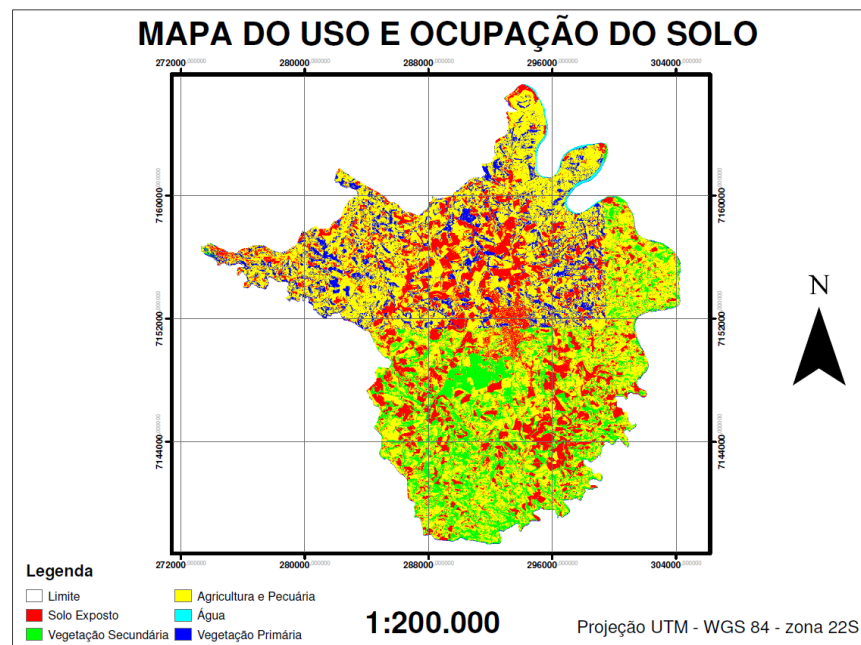
**Fonte: Adaptado de AMSOP (2008).**

Na Figura 15 é possível observar a imagem espectral para Dois Vizinhos que é delimitado ao noroeste pelo Rio Chopim, faz divisa com os municípios de Cruzeiro do

Iguaçu, São Jorge D'Oeste, Boa Esperança do Iguaçu, Salto do Lontra, Verê e Enéas Marques. É um município considerado essencialmente agrícola.

#### 4.2.2 Uso e Ocupação do Solo

A informação referente ao uso e ocupação do solo extraído da imagem espectral do satélite SPOT/5 está representada na Figura 16.

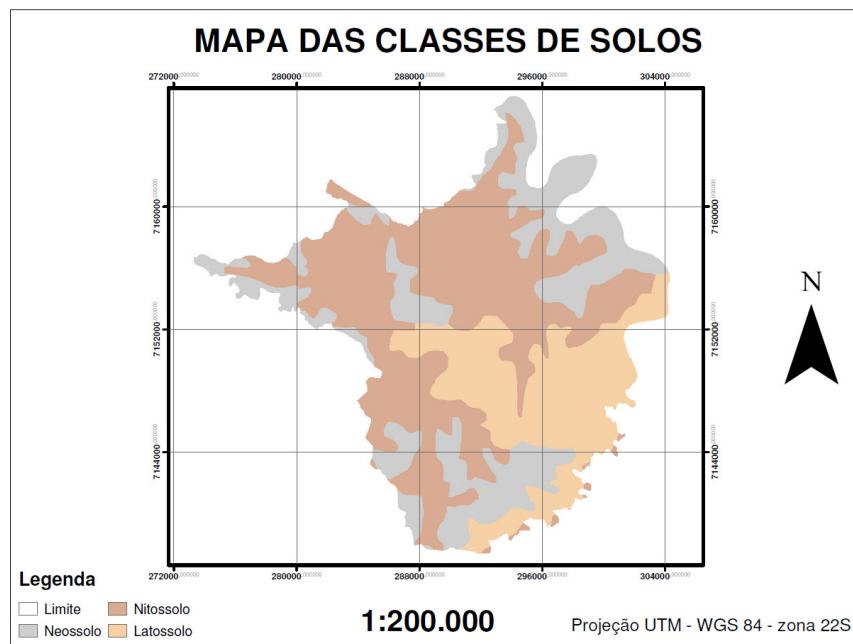


**Figura 16 - Imagem de uso e ocupação do solo de Dois Vizinhos.**  
**Fonte: Fonte: A Autora (2013).**

Pode ser observado na Figura 16 a classificação supervisionada referente ao uso do solo para o município de Dois Vizinhos, foram definidas 5 classes, sendo: solo exposto, vegetação secundária, vegetação primária, água e outra classe que foi agrupada pela dificuldade em diferenciar para a classificação, sendo áreas de agricultura e pecuária.

#### 4.2.3 Classe de Solo

Na Figura 17 está a representação das classes de solo que são encontradas no município de Dois Vizinhos.

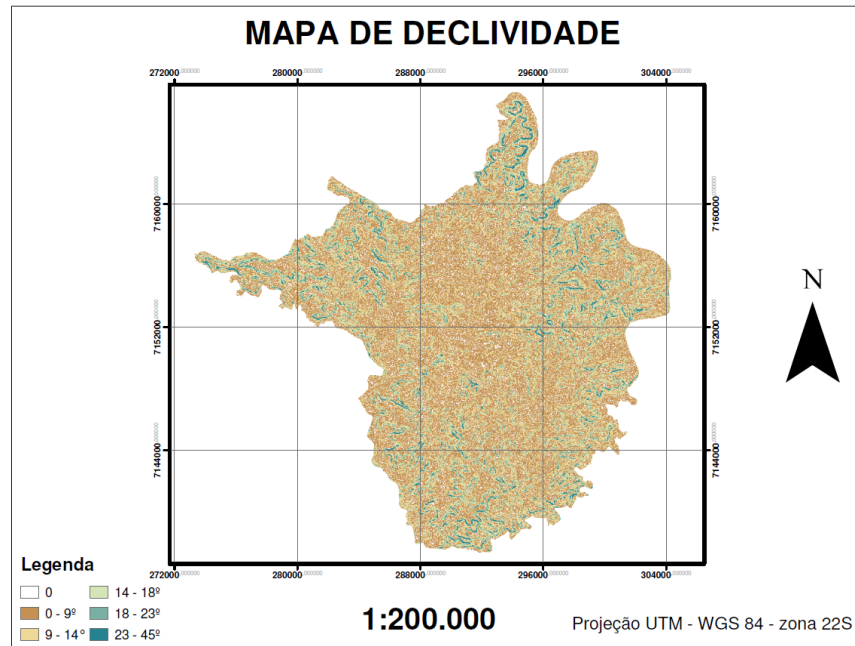


**Figura 17 - Classificação de solos para Dois Vizinhos.**  
**Fonte: Adaptado da Embrapa (2006).**

Na Figura 17, podem ser visualizadas as classes de solo para Dois Vizinhos, são encontrados três tipos de solo de acordo com a classificação da EMBRAPA (2006, p. 1), sendo, neossolo, nitossolo e latossolo.

#### 4.2.4 Informação de Declividade

As declividades encontradas no município de Dois Vizinhos estão representadas na Figura 18.

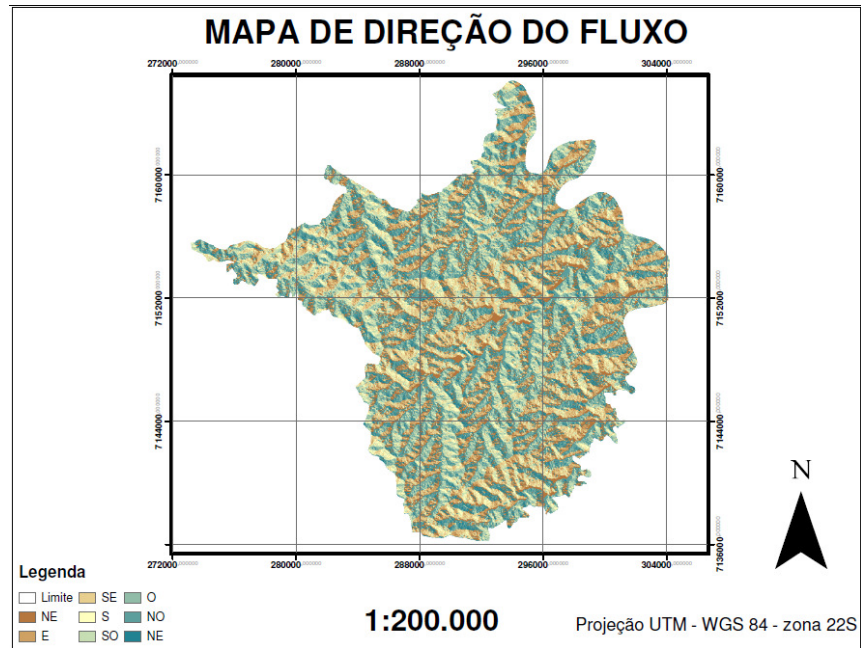


**Figura 18 - Declividade para o município de Dois Vizinhos**  
**Fonte: Fonte: A Autora (2013).**

Na Figura 18 pode-se observar a variação de declividade para o interior do município de Dois Vizinhos, a declividade varia de 0 à 45°.

#### 4.2.5 Direção do Fluxo

Com base na informação de declividade foi gerada a informação referente a direção do fluxo, representada na Figura 19.




**Figura 19 - Direção do fluxo para o município de Dois Vizinhos.**  
**Fonte: A Autora (2013).**

Na Figura 19, pode-se observar a imagem de direção do fluxo para Dois Vizinhos, determinação da direção de escoamento da água.

#### 4.2.6 Comprimento do Fluxo

O comprimento do fluxo gerado a partir da direção do fluxo, consta na Figura 20.



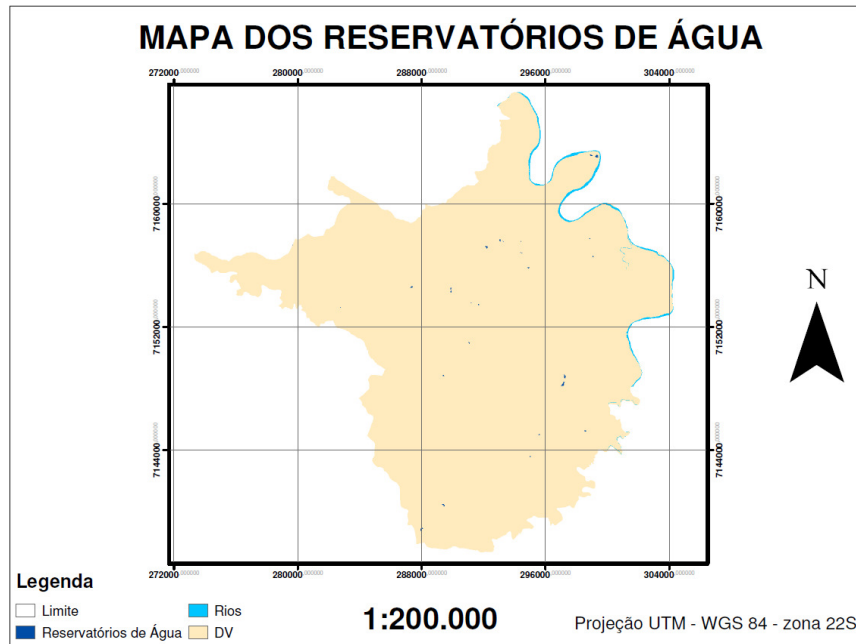
**Figura 20 - Informação de comprimento de fluxo para o município de Dois Vizinhos. Fonte: Fonte: A Autora (2013).**

O comprimento de fluxo para Dois Vizinhos varia de 0 à 39 m, indicando quanto maior o valor, maior a quantidade de pixels que contribuem para que a água escoe de um local a outro.

#### 4.2.7 Hidrografia

Na Figura 21 está representado o tipo e local dos reservatórios de água para Dois Vizinhos, segundo a classificação da Copel e Águas Paraná (2011).





**Figura 21 - Identificação dos reservatórios de água para o município de Dois Vizinhos.**  
**Fonte: Adaptado da Copel e Águas Paraná (2011).**

Na Figura 21 são encontrados reservatórios de água (açude) e rios para o interior do município, um dos rios é utilizado como delimitação de Dois Vizinhos.

### 4.3 INTEGRAÇÃO DOS DADOS NA REDE NEURAL ARTIFICIAL

#### 4.3.1 Treinamento da RNA

Após a integração dos dados na RNA variou-se os parâmetros de forma empírica e sucessivamente em busca de melhores resultados. Na segunda camada oculta variaram-se os neurônios sendo 10, 25, 40 e 55. A primeira camada oculta foi constituída de três vezes o número de neurônios da segunda camada oculta. O número de época foi de 500 á 9500 com incremento de 1000 épocas. A taxa de aprendizado foi de 0.1, 0.51 e 1.01. O momento foi de 0.1 com erro médio quadrático (RMS) de 0.00001.

O resultado obtido pela RNA que apontam deslizamentos na área experimental está disposto na Tabela 2 abaixo.

**Tabela 2 - Resultados da RNA para os dados de ocorrência, não ocorrência e dúvida.**

	Classificação como não ocorrência	Classificação como ocorrência	Dúvida
Média	44,40	51,86	3,73
Desvio Padrão	23,47	24,19	2,33
Coefficiente de variação	0,52	0,46	0,62
Maior acerto	47,02	49,16	3,80

**Fonte: A autora (2013).**

No treinamento a RNA apontou como ocorrência de deslizamento (valores maiores que 0,6) em média 51,86% de aproximadamente 100 treinamentos. Para a classe de não ocorrência (saída com valor menor que 0,4) obteve-se em média 44,40% dos resultados.

Para a classe intermediária (entre 0,4 e 0,6) classificada com sendo dúvida da RNA o valor médio foi de 3,73%.

Segue na Tabela 3 a relação da percentagem de acertos da RNA.

**Tabela 3 - Acertos da RNA.**

	Acertos / 100 % dos dados	Não ocorrência / 50 % dos dados	Ocorrência / 50 % dos dados
Média	81,49	42,57	38,92
Desvio Padrão	17,28	11,94	17,04
Coefficiente de variação	0,21	0,28	0,43
Maior Acerto	91,66	46,42	45,23

**Fonte: A autora (2013).**

Quando comparada a saída da RNA com os dados de verificação, pode-se observar que em média a RNA acertou 81,49%, o maior acerto foi de 91,66%, sendo que 46,42 são para a classe de não ocorrência e 45,23 para a classe de ocorrência de deslizamento, resultados estes encontrados na arquitetura de 40 neurônios na camada secundária, 120 neurônios na camada primária, momento de 0.01, taxa de aprendizado de 0.51 e 4.500 épocas.

O fator limitante para se alcançar acertos maiores de 91,66% no treinamento foi o tempo de processamento, capacidade de memória da máquina e processamento do software Matlab. Para a simulação das imagens de Dois Vizinhos foi necessário dividir sua área no meio e mesmo assim para processar a área toda do município foram necessárias 48 horas.

A RNA classificou em média 44,40% de um total de 50%, como sendo da classe de não ocorrência sendo que destes 42,57% são acertos. Já para a classe de ocorrência de deslizamento a RNA definiu como sendo 51,86 e os acertos somam 38,92%.

Na Tabela 4 está exposta a percentagem de erros de cada classe.

**Tabela 4 - Classificação errônea pela RNA.**

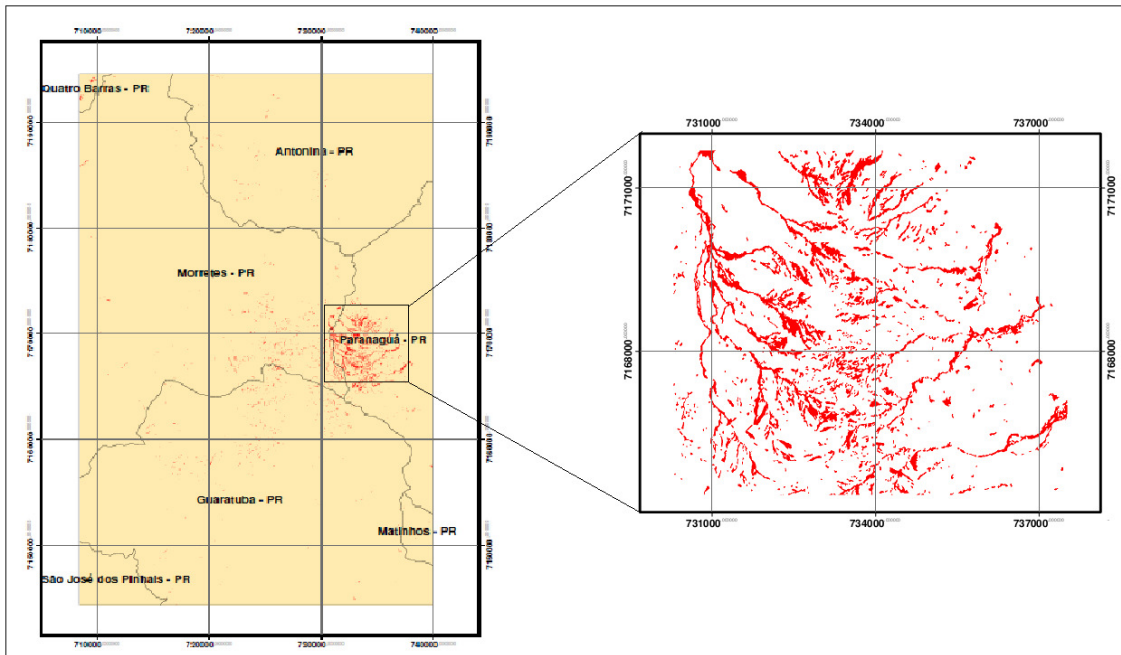
	Erros / 100 % dos dados	Não ocorrência / 50 % dos dados	Ocorrência / 50 % dos dados
Média	18,50	7,42	11,07
Desvio Padrão	17,28	11,94	17,04
Coefficiente de variação	0,94	1,60	1,53
Maior Acerto	8,33	4,76	3,57

**Fonte: A autora (2013).**

Considerando todo o conjunto de verificação, em média 18,50% dos resultados da RNA são errôneos, sendo a maior percentagem de erros na classe de ocorrência de deslizamento com 11,07% e para a classe de não ocorrência em média 7,42% de erros.

#### 4.3.2 Simulação da RNA


O recorte realizado sobre parte da área utilizada como treinamento que também foi utilizado para aplicar a simulação está representado na Figura 22



**Figura 22 – Recorte realizado sobre a área de ocorrência utilizado para realizar a simulação.**  
**Fonte: A autora (2013).**

Na Figura 22, pode ser observado o recorte usado para a simulação, para o recorte foi selecionada uma área que abrange o maior número de ocorrências.

O maior peso gerado pelo treinamento da RNA, o qual corresponde a 91,66% de acertos, foi passado para a simulação. A simulação da RNA para a mesma área de treinamento está disposta na Figura 23.

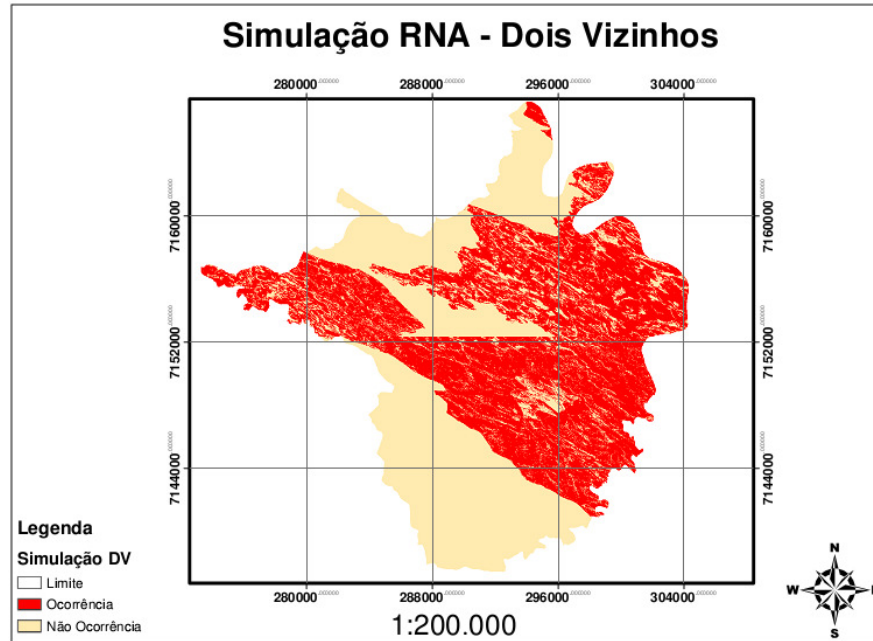


**Figura 23 – Resultado do apontamento de possíveis áreas de deslizamento, na região de ocorrência de deslizamento.**

**Fonte: A autora (2013).**

Pode-se observar comparando a Figura 22, está que representa as ocorrências registradas, com a Figura 23, esta resultante da classificação, que a RNA identificou a maior parte da imagem como ocorrência de deslizamento, superestimando as ocorrências. Este fato pode ser justificado pelo fato da RNA estar sendo utilizada para prever possíveis áreas de deslizamento a partir de características de eventos registrados e também por esta área ter um grande número de evento usado para o treinamento e apresentarem os mesmos padrões de ocorrência de deslizamento.

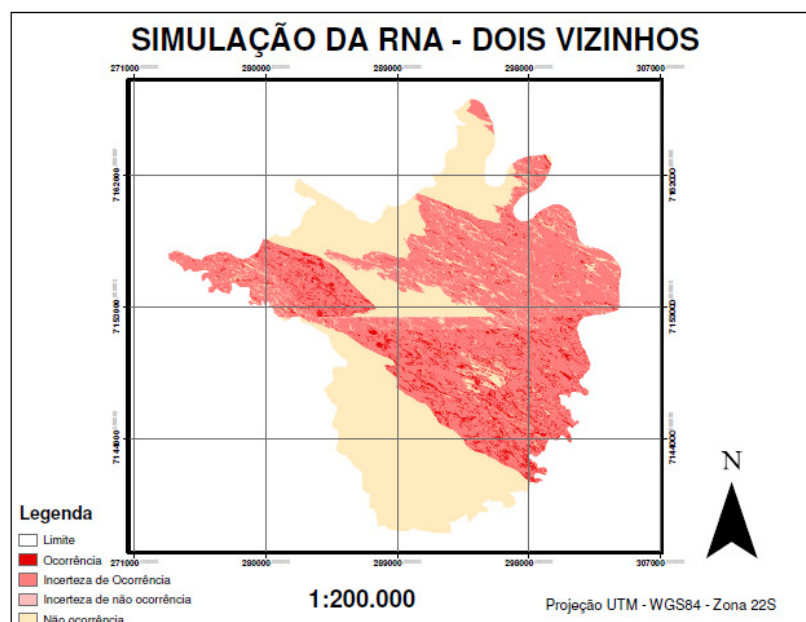
A aplicação da simulação para Dois Vizinhos e o apontamento para as áreas possíveis de ocorrerem deslizamento está representa na Figura 24.



**Figura 24 – Resultado da simulação da RNA para a cidade de Dois Vizinhos.**  
**Fonte: A autora (2013).**

Podem-se observar as áreas representadas pela cor vermelha (Figura 24), com esta que indica os apontamentos da RNA para ocorrência de deslizamento.

Na Figura 25 pode-se observar qual é o grau de risco para tais apontamentos da RNA.



**Figura 25 – Resultado da gravidade do deslizamento apontado pela RNA para o município de Dois Vizinhos.**  
**Fonte: A autora (2013).**

Na Figura 25, pode-se observar de acordo com os níveis de gravidade da simulação da RNA que grande parte dos apontamentos foram classificados como incerteza de ocorrência de deslizamento. Porém, nota-se que algumas áreas foram indicadas como passíveis de risco de desmoronamento (cor vermelha).

#### 4.4 AVALIAÇÕES DOS RESULTADOS

Tendo em mãos a imagem de simulação para o recorte da área de ocorrência e a imagem de referência, foi realizada a avaliação do índice kappa e a matriz de confusão que podem ser visualizados na Tabela 5.

**Tabela 5 - Avaliação da simulação**

Classificação	Comissão (%)	Omissão (%)	Exatidão do Produtor (%)	Exatidão do Usuário (%)
Ocorrência	88,58	51,71	48,29	11,42
Não Ocorrência	10,93	47,03	52,97	89,07

**Fonte: A autora (2013).**

Aplicando-se a avaliação na classificação da RNA, obteve-se 88,58% como sendo erros de comissão para a classe de ocorrência e 10,93% para a classe de não ocorrência, os erros de comissão correspondem a pixels que não se incluem em uma determinada categoria, são delimitações excessivas.

Foi encontrado 51,71% de erros de omissão para a classe de ocorrência e 47,03 para a classe de não ocorrência. Os erros de omissão representam os pixels que pertencentes a uma determinada categoria não foram incluídos nela, definição imperfeita da categoria.

Para a variável exatidão do produtor e exatidão do usuário a classe de não ocorrência se sobressaiu com 48,29% e 89,07% respectivamente. A acurácia do usuário ou do consumidor refere-se ao erro de comissão, enquanto a acurácia do produtor refere-se ao erro de omissão.

A percentagem de píxels que coincidiram na classificação (exatidão global) foi de 52.4431% e o índice kappa resultante foi de 0.0052, resultado além do proposto para classificação de Landis e Koch (1977, p. 165), o valor mais próximo de 1 é melhor.

Já para a cidade de Dois Vizinhos não se tem registros de ocorrência de deslizamento nos órgãos responsáveis por este tipo de evento, então não foi possível realizar o índice kappa.



## CONSIDERAÇÕES FINAIS

O treinamento da RNA foi satisfatório, pois este chegou ao acerto de 91,66%. Assim pode-se concluir que a RNA é capaz de aprender os padrões existentes em áreas de risco de deslizamento gerando um modelo apropriado para estes dados de entrada.

No processo de simulação, usando a área que foi utilizada para obter as amostras de treinamento, a RNA apontou mais áreas e com maior abrangência como sendo possíveis de ocorrerem deslizamentos. As formas de avaliação definidas como sendo o índice Kappa e exatidão global apresentaram valores ruins, fato este que pode ser justificado devido a RNA apontar locais que apresentam padrões semelhantes aos dos locais com episódio de deslizamento, enquanto a área mapeada pela empresa foi realizada pela sua visualização na superfície do relevo, ou seja, a região mapeada foi para evidenciar o que ocorreu no local enquanto a RNA destaca o que pode ocorrer levando em consideração o contexto do subsolo e da região entorno do evento.

Quanto a possibilidade de previsão de áreas diferentes a que foi treinada, nota-se que na simulação e identificação de áreas de risco para Dois Vizinhos a RNA apontou algumas áreas como propensas a ocorrerem deslizamentos, porém é necessário que seja verificado a campo pois nessa região não foi encontrado registros de ocorrência desses tipos de eventos nos últimos anos.

A RNA foi eficiente para modelar o problema em questão, porém teve um grande custo computacional para realização de seu processo, foram gastas muitas horas de processamento tanto para o processo de treinamento quanto para a simulação. Assim a otimização de seu processo por meio de linguagem de programação gerando uma plataforma mais sólida é importante para a continuação desse trabalho.

Recomendações para trabalhos futuros:

- Pesquisar por índices que representem a textura do solo (teor de argila e areia) ou até mesmo a capacidade do solo em infiltrar a água. Dessa forma acredita-se que o solo vai colaborar mais com o processo de aprendizagem, identificação e previsão para outras áreas.

- Verificar a importância de cada parâmetro de entrada da RNA, para que assim seja possível eliminar parâmetros irrelevantes e deixar a RNA mais leve para processamento.

- Para o treinamento da RNA usar pontos estratégicos, usar a informação do início do deslizamento e não desde o início até a área em que é depositado o material, pois o material é depositado em áreas com declividade baixa, por exemplo, e que era um tipo de solo estável.

- Utilizar imagem espectral coletada em períodos anteriores ao do deslizamento e em um período curto, para que dessa forma seja possível visualizar exatamente o que havia antes do evento obtendo informações mais acuradas dos fatos e gerando modelos mais acurados para posterior aplicação durante o processo de generalização.

- A precipitação tem fundamental importância, e o movimento de massa sempre está relacionado a períodos intensos de precipitação, recomenda-se ao fazer o registro de ocorrência de deslizamento que seja também considerada a precipitação em tal local.

- Construir um banco de dados com ocorrências de deslizamento não somente com regiões do estado do Paraná, mas de outros estados também, buscando a exemplificação dos mais diferentes tipos de solos e vegetações, assim como dos entrelaces com suas variações topográficas do relevo.

## REFERÊNCIAS

ABRANTES, Graça. M. **Sistemas de Informação Geográfica – Conceitos**. Lisboa: ISA, 5 p. 1998. Disponível em: <<http://www.isa.utl.pt/dm/sigdr/sigdr01-02/SIGconceitos.html>>. Acesso em: 02 fev. 2012.

AGUASPARANÁ - INSTITUTO DAS ÁGUAS DO PARANÁ. **Base Hidrográfica Unificada**. 2011, p. 1. Disponível em: <<http://www.aguasparana.pr.gov.br/>>. Acesso em: 11 jan. 2012.

ANEAS DE CASTRO, S. D. “Riesgos y peligros: una visión desde lá Geografía”. Scripta Nova: **Revista Electrónica de Geografía y Ciencias Sociales**. Barcelona, n.60, 15 de mar. 2000. Disponível em: <<http://www.ub.es/geocrit/sn-60.htm>>. Acesso em: 02 fev. 2012.

AUGUSTO FILHO, Oswaldo; VIRGILI, J. C. **Estabilidade de Taludes**. 1998. In: Oliveira, A.M.S. e De Brito, S.N.A., Geologia de Engenharia. 1. ed. São Paulo: Associação Brasileira de Geologia de Engenharia. 1998. 582 p.

BAGLI, Vantier V. **Mosaico de imagens de sensoriamento remoto**. 2005. Proposta de Dissertação de Mestrado em Computação Aplicada - INPE. 60p. 2005.

BERTONI, José; LOMBARDI NETO, Francisco. **Conservação do Solo**. 8 ed. 2012, 360 p.

BERNARDES, Tiago; ALVES, Helena M. R.; VIEIRA, Tatiana G. Classificação automática de imagens de satélites no mapeamento da região cafeeira de patrocínio, MG. In: SIMPÓSIO DE PESQUISA DOS CAFÉS DO BRASIL 2007, Águas de Lindóia, SP. **Anais...** Brasília, DF: Embrapa Café, 2007.

BLASCHKE, Thomas; BURNETT, Charles; PEKKARINEN, Anssi. Image segmentation methods for object-based analysis and classification. In: De Jong, S. M. & Der Meer, F. D. (eds). **Remote sensing image analysis – including the spatial domain**. Dordrecht, The Netherlands, Springer. 2006. 211-236 p.

BOTELHO, Mosar. **Aplicação de redes neurais na classificação de imagens de alta resolução espacial e dados do laser scanner, usando uma abordagem orientada a regiões**. 2004. 103 f. Dissertação – (Mestrado em ciências geodésicas), Universidade Federal do Paraná, Curitiba, 2004. Disponível em: <[http://dspace.c3sl.ufpr.br/dspace/bitstream/handle/1884/8014/Dissertacao\\_Mosar\\_Final.pdf?sequence=1](http://dspace.c3sl.ufpr.br/dspace/bitstream/handle/1884/8014/Dissertacao_Mosar_Final.pdf?sequence=1)>. Acesso em: 24 maio 2012.

BOTELHO, Mosar. F.; VIEIRA, Carlos A. O. Aplicação de redes neurais para identificação de feições espaciais. In: WORKSHOP SOBRE GEOPROCESSAMENTO DA UFV, 2002, Viçosa-MG. **Anais...** 2002.

CAMPBELL, James B. **Introduction to remote sensing**. New York: The Guilford Press, 1996. 622 p.

CARTWRIGHT, Kenneth V. Determining the Effective or RMS Voltage of Various Waveforms without Calculus. **Technology Interface**, vol. 8, n.1, 20 p, 2007.

CASSETI, Valter. **Ambiente e apropriação do relevo**. São Paulo: Contexto, 1991. 137p.

CASTRO, Cleber M.; PEIXOTO, Maria N. O.; RIO, Gisela A. P. **Riscos Ambientais e Geografia: Conceituações, Abordagens e Escalas**. Anuário do Instituto de Geociências - UFRJ. 28-2, 2005, 11-30p. Disponível em: <[http://www.anuario.igeo.ufrj.br/anuario\\_2005/Anuario\\_2005\\_11\\_30.pdf](http://www.anuario.igeo.ufrj.br/anuario_2005/Anuario_2005_11_30.pdf)>. Acesso em: 22 mar. 2012.

CENTENO, Jorge A. S. **Sensoriamento remoto e processamento de imagens digitais**. 1ed, v.1. 209p. 2004.

CHRISTOFOLETTI, Antônio. **Geomorfologia fluvial**. São Paulo: Edgard Blücher, 1981, 313 p.

COHEN, J. A coefficient of agreement for nominal scales. *Educational and psychological measurement*, v. 20, n.1, p. 37-46, 1960.

COPEL. **Base Hidrográfica Unificada**. 2011, p. 1. Disponível em: <<http://www.copel.com>>. Acesso em: 17 jan. 2011.

DEBASTIANI, Aline B.; BOTELHO, Mosar F.; SOUZA, Mauricio.; SANTOS, Marcielli A. B. Utilização da Rede Neural Artificial para identificar padrões de áreas de risco de deslizamento do estado do Paraná. In: XVII Seminário de Iniciação Científica e Tecnológica, Curitiba/PR, **Anais...** Curitiba, 2012, 7 p. CD-ROM.

DIAS, Fernando P.; Herrmann, Maria L. de P. Susceptibilidade a deslizamentos: estudo de caso no Bairro Saco Grande, Florianópolis – SC. **Caminhos de Geografia - Revista On Line**, Programa de Pós Graduação em Geografia, 2002.

DIAS, Leonardo S. de O. **Identificação de áreas suscetíveis a deslizamento de terra utilizando sistema de informações geográficas**. 2006, 75p. Dissertação (Mestrado em Engenharia Ambiental Urbana) - Universidade Federal da Bahia, 2006. Disponível em: <[http://www.geotecnia.ufba.br/arquivos/disert\\_leonardo.pdf](http://www.geotecnia.ufba.br/arquivos/disert_leonardo.pdf)>. Acesso em: 24 maio 2012.

ERSDAC - EARTH REMOTE SENSING DATA ANALYSIS CENTER. **ASTER Global Digital Elevation Model (GDEM)**. Disponível em: <<http://www.ersdac.or.jp/GDEM/E/1.html>>. Acesso em: 17 de jan. 2011.

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

FELGUEIRAS, Carlos A. Análise espacial de dados geográficos: Modelo numérico do terreno. 2001. 38 p.

FERNANDES, Nelson F. et al. Condicionantes Geomorfológicos dos Deslizamentos nas Encostas: Avaliação de Metodologias e Aplicações de modelo de Previsão de Áreas Suscetíveis. **Revista Brasileira de Geomorfologia**, v.2, n.1, 2001, p.51-71.

FERNANDES, Nelson F.; AMARAL, Cláudio P. Movimentos de massa: uma abordagem geológico-geomorfológica. 1996. In: Guerra, A.J.T.; Cunha, S. ed. **Geomorfologia e meio ambiente**. Rio de Janeiro: Bertrand Brasil, 1996, 123-194 p.

FIDALGO, Elaine C. C. **Exatidão no processo de mapeamento temático da vegetação de uma área de mata atlântica no estado de São Paulo, a partir de imagens TM-Landsat**. 1995. 186 f. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 1995.

FITZ, Paulo Roberto. **Geoprocessamento sem complicação**. São Paulo: Oficina de Textos, 2008.

FRANCISCO, Cristiane N. Mapeamento das áreas de riscos de deslizamentos e desmoronamentos do parque nacional da Tijuca (RJ) e entorno através de sistemas geográficos de informação. In: 1ª Semana Estadual de Geoprocessamento, 1996, Rio de Janeiro, **Anais...** p. 197- 209, 1996. Disponível em: <<http://www.carto.eng.uerj.br/fgeorj/segeo1996/120/index.htm>>. Acesso em: 18 fev. 2012.

GEOCOVER. **Applied Science \$ Technology Project Office**. 2000, p. 1. Disponível em: <<http://zulu.ssc.nasa.gov/mrsid/>>. Acesso em: 20 fev. 2012.

GERMAN, G. W. H. e GAHEGAN, M. N. Neural Network Architectures for the Classification of Temporal Image Sequences. *Computers & Geosciences*, v.22, n.09, p.969-979, 1996.

GONÇALVES, Márcio L.; ANDRADE NETO, Márcio L.; ZULLO Jr., Jurandir. Comparação de uma arquitetura neural com o algoritmo de máxima verossimilhança na classificação de uma cena LANDSAT/TM. In: Simpósio Brasileiro de Sensoriamento Remoto, 9 ed. **Anais**. Santos, São Paulo, INPE, 969-980 p., 1998.

GRAY, Donald. Influence of vegetation on the stability os slopes. In: International Conference on the Interaction of Vegetation with Natural and Formed Slopes, 1994, Oxford. **Proceeding**...London: Thomas Telford, p.2-25, 1995.

GUERRA, Antonio J. T.; CUNHA, Sandra B. da. **Geomorfologia: uma atualização de conceitos e bases**. Rio de Janeiro: Bertrand Brasil, 1994, 23-45p.

GUIDICINI, Guido; NIEBLE, Carlos M. **Estabilidade de taludes Naturais e de Escavação**. 2ª ed., São Paulo: Edgard Bluche, 1984, 194p.

GUIDICINI, Guido; NIEBLE, Carlos M. **Estabilidade de taludes naturais de escavação**. 2 ed. São Paulo: Edgard Blücher, 1993. 196 p.

HAYKIN, Simon. **Redes neurais: Princípios e prática**. Porto Alegre: Bookman, 2001. 900 p.

ICMC. **Redes Neurais Artificiais**. 2012, 7p. Disponível em: <<http://www2.icmc.usp.br/~andre/research/neural/index.htm>>. Acesso em: 11 out. 2012.

JENSEN, John R. **Remote sensing of the environment**. 2.ed. NJ: Prentice Hall, 2007.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v.33, p. 159-174, 1977.

MARCELINO, Emerson V. **Mapeamento de áreas suscetíveis a escorregamento no município de Caraguatatuba (SP) usando técnicas de sensoriamento remoto e SIG**. 2003. 218f. São José dos Campos. 218p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais, 2003. Disponível em: <[http://www.inpe.br/crs/geodesastres/conteudo/teses/Marcelino%20E\\_2004\\_Mapeamento\\_de\\_areas\\_susceptiveis\\_a\\_escorregamento\\_no\\_municipio.pdf](http://www.inpe.br/crs/geodesastres/conteudo/teses/Marcelino%20E_2004_Mapeamento_de_areas_susceptiveis_a_escorregamento_no_municipio.pdf)>. Acesso em: 23 mai. 2012.

MEIRELLES, Ana F.; REIS, Ruibran J. Diagnóstico de áreas de risco associadas à precipitação no município de Betim, MG: estudo de caso dos períodos chuvosos de 2006-2007 e 2007-2008. In: XIII Simpósio Brasileiro de Geografia Física Aplicada, 2007, Viçosa.

MENDES, Carlos A. B., CIRILO, José A. Geoprocessamento em Recursos Hídricos: Princípios, Integração e Aplicação. Porto Alegre: ABRH, 2001. cap. 2. p. 57-111.

MINEROPAR. **Ocorrências de Deslizamentos**. 2011. Disponível em: <http://www.mineropar.pr.gov.br/>. Acesso em: 12 jan. 2012.

MONGUILHOTT, Michele. **Estudo de áreas suscetíveis á movimentos de massa na rodovia RS/486 – rota do sol**. 2008. 114p.. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul. 2008.

MOREIRA, Maurício A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. Viçosa, 3 ed., 2005. 320 p.

NASA - NATIONAL AERONAUTICS AND SPACE ADMINISTRATION. **Landsat Geocover, 2000**. Disponível em: <<https://zulu.ssc.nasa.gov>>. Acesso em: 18 de set. 2011.

NETTO, Ana Luiza C. **Hidrologia de encosta na interface com a Geomorfologia**. 1994. In: Guerra, A.J.T.; Cunha, S. ed. Geomorfologia: uma atualização de conceitos e bases, Rio de Janeiro: Bertrand Brasil, 1994, 93-148 p.

NOVO, E. M. L. de M.. **Sensoriamento Remoto**. 5.ed. Blucher: São Paulo, 2008.

OSÓRIO, Fernando; BITTENCOURT, João R. Sistemas inteligentes baseados em RNAs aplicados ao processamento de imagens. In: Workshop de Inteligência Artificial, 2000, Santa Cruz do Sul: UNISC. **Anais...** 2000.

REBOUÇAS, Sílvia; SOUSA, Lisete; PIRES, Ana. **METODOLOGIAS DE CLASSIFICAÇÃO SUPERVISIONADA PARA ANÁLISE DE DADOS DE MICROARRAYS. Notas e Comunicações do Centro de Estatística e Aplicações da Universidade de Lisboa**, 2009, Lisboa-Portugal. Disponível em: <<http://www.ceaul.fc.ul.pt/getfile.asp?where=notas&id=270>>. Acesso em: 05 Out. 2010.

RENNÓ, Camilo D.; NOBRE, Antonio D.; CUARTAS, Luz A.; SOARES, João V.; HODNETT, Martin G.; TOMASELLA, Javier.; WATERLOO, Maarten J. Remote Sensing of Environment. **Remote Sensing of Environment**, 2008, 13 p.

RICHARDS, J. A. **Remote Sensing Digital Image Analysis**, 5 ed, New York, 2013. 494 p.

RICKSON, R. J. Simulated vegetation and geotextiles. In: MORGAN, R.P.C.; RICKSON, R.J. (Eds.). **Slope stabilization and erosion control a bioengineering approach**. London: E&FN Spon, p. 95-125, 1995.

SANTOS, Álvaro R. **A grande barreira da serra do mar: da trilha dos Tupiniquins à rodovia dos Imigrantes**. São Paulo: O nome da Rosa, 2004, 122p.

SELBY, M. J. **Hillslope materials and processes**. 2ed. Oxford: Oxford Univ. Press, 1993. 451p.

SILVA, Marcos A. da. **Aplicação de Lógica Nebulosa para Previsão do Risco de Escorregamentos de Taludes em Solo Residual**. 2008. Dissertação (PGECIV) – Pós Graduação em Engenharia Civil, Universidade do Estado do Rio de Janeiro. 2008. Disponível em: < <http://www.labbas.eng.uerj.br/pgeciv/nova/files/dissertacoes/21.pdf>>. Acesso em: 24 abr. 2012.

TATIZANA, Celso; Ogura, Agostinho Tadashi; CERRI, Lendro E. da Silva; ROCHA, Mirian Cassia Médici. Escorregamentos – Serra do Mar, Municípios de Cubatão. In: 5º congresso brasileiro de geologia e engenharia. **Anais...** São Paulo, 1987.

THOMAS, M. F. **Tropical geomorphology: a study of weathering and landform development in warm climates**. 2 ed. London: MacMillan, 1979.

TSO, Brandt.; MATHER, Paul M., 2001. Classification methods for re-motely sensed data. Taylor and Francis, New York.

VANACÔR, ROBERTO N. **Sensoriamento remoto e geoprocessamento aplicados ao mapeamento das áreas susceptíveis a movimentos de massa na região nordeste do estádio do Rio Grande do Sul**. 2006, 128 f. Dissertação – (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, 2006. Disponível em: <<http://www.lume.ufrgs.br/bitstream/handle/10183/8344/000574101.pdf?sequence=1>>. Acesso em: 24 maio 2012.

WOLLE, Claudio M. **Análise de escorregamentos translacionais numa região da Serra do Mar no contexto de uma classificação de mecanismos de instabilização de encostas**. 1988, 800 f. (Tese - Doutorado em Engenharia) - Universidade de São Paulo, Escola Politécnica, São Paulo. 1988.



XAVIER, Fernando F.; BERKENBROCK, Paulo E. Estudo de risco a escorregamentos em área urbana no município de BLUMENAU, SC. 11º In: Congresso Brasileiro de Geologia de Engenharia e Ambiental. **Anais eletrônicos...** Florianópolis, SC, 2005. Disponível em: <<http://www.tecgeofisica.com.br/publicacoes/risco.pdf>>. Acesso em: 23 abr. 2012.