

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL

**METODOLOGIA PARA APLICAÇÃO DE REDES NEURAIAS
ARTIFICIAIS PARA SISTEMAS DE ALERTA DE
ESCORREGAMENTOS DEFLAGRADOS POR CHUVAS EM
REGIÕES MONTANHOSAS**

EDUARDO MONTOYA BOTERO

ORIENTADOR: HERNAN EDUARDO MARTINEZ CARVAJAL, D.Sc.
CO – ORIENTADOR: EDWIN FABIAN GARCIA ARITIZABAL, D.Sc.

TESE DE DOUTORADO EM GEOTECNIA

PUBLICAÇÃO: G. TD-141/18

BRASÍLIA / DF: JUNHO/2018

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA CIVIL E AMBIENTAL

METODOLOGIA PARA APLICAÇÃO DE REDES NEURAIS
ARTIFICIAIS PARA SISTEMAS DE ALERTA DE
ESCORREGAMENTOS DEFLAGRADOS POR CHUVAS EM
REGIÕES MONTANHOSAS

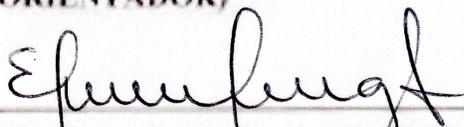
EDUARDO MONTOYA BOTERO

TESE DE DOUTORADO EM GEOTECNIA SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA
CIVIL E AMBIENTAL DA UNIVERSIDADE DE BRASÍLIA COMO PARTE DOS REQUISITOS
NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR.

APROVADA POR:



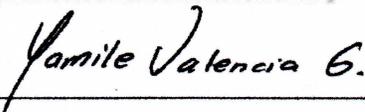
HERNAN EDUARDO MARTINEZ CARVAJAL, D.Sc. (UNAL)
(ORIENTADOR)



EDWIN FABIAN GARCIA ARISTIZABAL, D.Sc. (UdeA)
(COORIENTADOR)



ANDRÉ LUIS BRASIL CAVALCANTE, D.Sc. (UnB)
(EXAMINADOR INTERNO)



YAMILE VALENCIA GONZALEZ, D.Sc. (UNAL)
(EXAMINADOR EXTERNO)



MARIA TAMARA DE MORAES GUIMARAES SILVA, D.Sc. (IFG)
(EXAMINADOR EXTERNO)

DATA: BRASÍLIA/DF, 21 JUNHO DE 2018.

FICHA CATALOGRÁFICA

MONTOYA BOTERO, EDUARDO

Metodologia para Aplicação de Redes Neurais Artificiais para Sistemas de Alerta de Escorregamentos Deflagrados por Chuvas em Regiões Montanhosas;

xi, 87 p., 210x297 mm (ENC/FT/UnB, Doutor, Geotecnia, 2018)

Tese de Doutorado - Universidade de Brasília.

Faculdade de Tecnologia. Departamento de Engenharia Civil e Ambiental

1. Escorregamentos

2. Redes Neurais Artificiais

3. Precipitação

4. Infiltração em Solos Não Saturados

I. ENC/FT/UnB

II. Título (série)

REFERÊNCIA BIBLIOGRÁFICA

Montoya, E. (2018). Metodologia para aplicação de redes neurais artificiais para sistemas de alerta de escorregamentos deflagrados por chuvas em regiões montanhosas, Publicação G.TD-141/18, Departamento de Engenharia Civil e ambiental, Universidade de Brasília, Brasília, DF, 87 p.

CESSÃO DE DIREITOS

NOME DO AUTOR: Eduardo Montoya Botero

TÍTULO DA TESE DE DOUTORADO: Metodologia de Uso de Redes Neurais Artificiais para Sistemas de Alerta de Escorregamentos Deflagrados por Chuvas em Regiões Montanhosas

GRAU / ANO: Doutor/2018

É concedida à Universidade de Brasília a permissão para reproduzir cópias desta dissertação de mestrado e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito do autor.

Eduardo Montoya Botero

SQS 413 BLOCO L APARTAMENTO 301

70296120 - Brasília/DF - Brasil

AGRADECIMENTOS

Ao professor Hernan Martinez pela oportunidade de crescimento acadêmico.

Agradeço ao professor Edwin pelas orientações durante a elaboração deste trabalho.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), e ao projeto Marie Curie IRSES - GREAT 'Geotechnical and geological Responses to climate change: Exchanging Approaches and Technologies on a world-wide scale' (FP7-PEOPLE-2013-IRSES-612665), pelo apoio financeiro.

RESUMO

Neste trabalho, apresenta-se uma metodologia para aplicação de Redes Neurais Artificiais para sistemas de alerta de escorregamentos superficiais deflagrados por chuvas. A metodologia aqui descrita foi aplicada, a título de exemplo, em uma área montanhosa do município de Barbosa (Colômbia). Foi necessária a construção de uma base de dados artificial, composta por 270 exemplos, produtos da combinação de três declividades representativas, cinco chuvas típicas do local de estudo, caracterizadas pela sua duração e intensidade, três espessuras de profundidade da superfície potencial de deslizamento, três condições iniciais do lençol freático e dois tipos de solo. Foram feitas as combinações dessas variáveis e, assim, obtido o perfil de poropressões em um código de Elementos Finitos, para conseguir a curva de poropressão *versus* profundidade num corte horizontal, em cada um dos casos analisados. De posse desse perfil, é demonstrado como é possível calcular um indicativo de ameaça e se procede à confecção do cálculo de maneira especializada, permitindo obter cartas, onde é possível identificar áreas com diferentes níveis de ameaça para um determinado evento de chuva. Dessa forma, as entradas para o modelo de rede neural presente nesta pesquisa são a declividade, precipitação, profundidade da superfície potencial de deslizamento, profundidade do lençol freático e o tipo de solo; e a resposta do modelo de rede neural o perfil de poropressão para essa encosta sob a condição de chuva imposta e uma geometria definida. Verificou-se a capacidade que as Redes Neurais têm de aprender com informação característica do problema estudado e fornecer resposta, com um erro mínimo, para qualquer outra condição, generalizando o problema e permitindo aplicar a ferramenta em um local com condições hidrológicas, geológicas e topográficas similares.

ABSTRACT

This work presents a methodology for the application of Artificial Neural Networks for warning systems of rainfall landslides. The methodology described here was applied, as an example, in a mountainous area of the municipality of Barbosa (Colombia). It was necessary to construct an artificial database, consisting of 270 examples, products of the combination of three representative slopes, five typical rains of the study site, characterized by their duration and intensity, three depths of the potential sliding surface, three initial conditions of the water table and two types of soil. The combinations of these variables were made and, thus, the pore pressure profile was obtained in a Finite Element code, to obtain the pore pressure curve versus depth in a horizontal cut in each of the analyzed cases. In the possession of this profile, it is shown how it is possible to calculate a threat code and proceed with the preparation of the calculation in a specialized manner, allowing to obtain letters where it is possible to identify areas with different threat levels for a given rain event. Therefore, the inputs to the neural network model present in this research are the slope, precipitation, potential slip surface depth, groundwater depth and soil type; and the response of the neural network model the pore pressure profile for that slope under the condition of imposed rain and a defined geometry. It was verified the ability of the Neural Networks to learn with characteristic information of the problem studied in order to give a response, with a minimum error, to any other condition, generalizing the problem and allowing applying the tool in a place with similar hydrological, geological and topographical conditions.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	MOTIVAÇÃO.....	1
1.2	HIPÓTESES E OBJETIVOS	3
2	REVISÃO DA LITERATURA.....	4
2.1	CLASSIFICAÇÃO DOS MOVIMENTOS DE MASSA.....	4
2.1.1	QUEDAS.....	5
2.1.2	TOMBAMENTOS	6
2.1.3	DESLIZAMENTOS.....	6
2.1.4	EXPANSÕES LATERAIS	6
2.1.5	CORRIDAS.....	6
2.2	CAUSAS DOS MOVIMENTOS DE MASSAS.....	7
2.3	ESTABILIDADE DE TALUDES EM SOLOS	9
2.4	INTELIGÊNCIA ARTIFICIAL	14
2.5	REDES NEURAIAS ARTIFICIAIS (RNAs)	15
2.5.1	PRINCIPAIS ARQUITETURAS DE RNAs	16
2.5.2	NEURÔNIOS BIOLÓGICOS E ARTIFICIAIS.....	17
2.5.3	FUNÇÕES DE ATIVAÇÃO	18
2.5.4	PROCESSO DE APRENDIZAGEM.....	19
2.5.5	REDES MULTI LAYER PERCEPTRON (MLP).....	21
2.5.6	AS REDES NEURAIAS EM ENGENHARIA CIVIL.....	24
2.5.7	AS REDES NEURAIAS EM GEOTECNIA	25
3	MATERIAIS E MÉTODOS	27
3.1	ÁREA DE ESTUDO	27
3.2	ESTRUTURA METODOLÓGICA	28
3.3	ETAPA 1: COLETA E ESPACIALIZAÇÃO DA INFORMAÇÃO.....	28
3.3.1	MAPA DE DECLIVIDADE.....	28
3.3.2	PROPRIEDADES DO SOLO.....	30

3.3.3	UNIDADES GEOLOGICAS	30
3.3.4	PARÂMETROS GEOTÉCNICOS	31
3.3.5	ESPESSURA DO SOLO INTEMPERIZADO.....	32
3.3.6	CURVA CARACTERÍSTICA SOLO-ÁGUA	35
3.3.7	CHUVA.....	37
3.3.8	CHUVA ANTECEDENTE.....	38
3.4	ETAPA 2: ANALISE NUMERICA DE INFILTRAÇÃO.....	39
3.5	ETAPA 4: TREINAMENTO E VALIDAÇÃO DO MODELO DE RNA	39
3.6	ETAPA 4: CÁLCULO DO INDICATIVO DE ESTABILIDADE.....	41
3.6.1	FATOR DE SEGURANÇA.....	41
3.7	ETAPA 5: ELABORAÇÃO DE MAPAS DE AMEAÇA	43
4	RESULTADOS	46
4.1	ESPESSURA DO SOLO.....	46
4.2	CHUVAS PARA O TREINAMENTO DA RNA	47
4.3	CURVA CARACTERISTICA	48
4.4	ANALISES NUMÉRICAS DE INFILTRAÇÃO	49
4.4.1	ESCOLHA DA MALHA DE ELEMENTOS FINITOS.....	51
4.4.2	ARQUITETURA E TREINAMENTO DO MODELO DE REDE NEURONAL 52	
4.5	CALCULO DO FATOR DE SEGURANÇA.....	55
4.6	MAPAS DE AMEAÇA.....	55
5	CONCLUSÕES E RECOMENDAÇÕES.....	61
6	REFERÊNCIAS	64

LISTA DE TABELAS

Tabela 1.1. Eventos trágicos na historia de Medellín, produzidos por deslizamentos de massa. (Isaza-Restrepo, 2011)	2
Tabela 2.1. Resumo da classificação dos movimentos de massa Cruden & Varnes (1996).....	5
Tabela 2.2. Classificação dos escorregamentos segundo a sua velocidade. Cruden & Varnes (1996)	5
Tabela 3.1. Porcentagem da área com respeito à área total de movimentos de massa (Garcia, 2006).....	29
Tabela 3.2. Parâmetros geotécnicos empregados.....	32
Tabela 4.1. Eventos de chuva para treinamento validação e verificação do modelo de RNA.	47
Tabela 4.2. Parâmetros hidráulicos. Fresneda, C. (2017)	48
Tabela 4.3. Variáveis para o treinamento do modelo de RNA	50
Tabela 4.4. Chuvas para elaboração mapas de ameaça.....	55
Tabela 4.5. Porcentagem de área acumulada	60

LISTA DE FIGURAS

Figura 2.1.A:Quedas, B:Tombamentos, C.1:Deslizamento rotacional, C.2: deslizamento translacional, D: expansão lateral, E: corridas. (USGS, 2004)	7
Figura 2.2. Densidade de probabilidade de movimentos de massa (Malamud et al., 2004) modificado.....	8
Figura 2.3. Classificação proposta de métodos de avaliação de ameaça de terra (modificado Aleotti & Chowdhury, 1999)	12
Figura 2.4. Principais arquiteturas de RNAs. Modificado de (Braga et al, 2000).	16
Figura 2.5. Modelo artificial de um neurônio (Haykin, 2001).....	18
Figura 2.6. Funções de ativação mais usadas: a)limiar, b-1 e b-2)linear, c)sigmoide: logística c-1), tangente hiperbólica c-2), Gaussiana c-3). (Martinez, 2006)	19
Figura 2.7. Processo de aprendizagem de uma RNA (Biswajeet & Saro, 2007).....	20
Figura 3.1. Localização do município de Barbosa – Colômbia	27
Figura 3.2. Metodologia da presente pesquisa.	28
Figura 3.3. Mapa de declividade da área de estudo	29
Figura 3.4. Geologia da área de estudo. (Modificado de AREA (2002))	30
Figura 3.5. Curvas de estimativa de profundidade para valores limites de declividade distintos.	34
Figura 3.6. Curva Intensidade - Duração - Frequência. Gomez (2002).....	38
Figura 3.7. Diagrama de corpo livre talude infinito. (Modificado Lade, (2010))......	42
Figura 3.8. Metodologia para elaboração de mapas de ameaça	44
Figura 3.9. Árvore de decisões.....	45
Figura 4.1. Sequencia calculo de ameaça.....	46
Figura 4.2. Mapa de espessura do solo.....	47
Figura 4.3. Curva característica solo-agua deposito aluvial.....	48
Figura 4.4. Curva característica solo agua solo residual	49
Figura 4.5. Esquemática geometria encosta	50
Figura 4.6. Modelo de perfil poropressão SEEP-W	51
Figura 4.7. Modelo de perfil poropressão 'linearizado"	51
Figura 4.8. Escolha malha de elementos finitos.....	52
Figura 4.9. Resultados correlação RNA para argilas-siltosas	54
Figura 4.10. Resultados correlação RNA para areias-siltosas	54
Figura 4.11. Fator de segurança caso 1	56

Figura 4.12. Fator de segurança caso 2	56
Figura 4.13. Fator de segurança caso 3	57
Figura 4.14. Fator de segurança caso 4	57
Figura 4.15. Fator de segurança caso 5	58
Figura 4.16. Fator de segurança caso 6	58
Figura 4.17. Fator de segurança caso 7	59
Figura 4.18. Fator de segurança caso 8	59
Figura 4.19. Fator de segurança caso 9	60
Figura 5.1. Iso-valores de porcentagem de área falhada	62

1 INTRODUÇÃO

Os movimentos em massa constituem uma das causas mais frequentes de perdas humanas e econômicas ao redor do mundo, razão pela qual a determinação da ameaça por movimentos em massas e a capacidade de prever ditos eventos têm sido temas de grande interesse para a comunidade científica (Aleotti & Chowdhury, 1999; Chacón et al. 2006).

Em ambientes tropicais, caracterizados por perfis de intemperismo profundos e alta pluviosidade, um número importante de investigadores tem se concentrado em entender a chuva como o fator detonante na ocorrência desses movimentos em massa (Montgomery & Dietrich 1994; Crosta 1998; Polemio & Petrucci 2000; Iverson 2000; Larsen & Rainfall-triggered, 2008; Aristizábal et al. 2010). Segundo Schuster & Highland (2007) apesar dos avanços significativos na aplicação de medidas de mitigação, o crescimento da população tem resultado em aumento de risco de deslizamentos em encostas urbanas, sendo que o mecanismo deflagrador mais comum nesses casos é o excesso de chuva.

Desse modo, torna-se necessária a inclusão de considerações sobre tal fenômeno em abordagens sobre o uso do solo e no planejamento de ações de emergência para a segurança pública, bem como para a elaboração e execução de projetos seguros de engenharia (Fell et al., 2008).

Com o anteriormente exposto surge a ideia de utilizar as RNA devido a sua capacidade de *aprender* através de exemplos e de *generalizar* a informação aprendida. A generalização, que esta associada à capacidade de a rede aprender através de um conjunto reduzido de exemplos e posteriormente dar respostas corretas para dados não conhecidos, é uma demonstração de que a capacidade das RNA vai muito além de simplesmente mapear relações de entrada e saída. As RNA são capazes de extrair informações não apresentadas de forma explícita através dos exemplos. Outra característica importante é a capacidade de auto-organização e de processamento temporal, que faz das RNAs uma ferramenta computacional extremamente poderosa e atrativa para a solução de problemas complexos. (Braga et al, 2000).

1.1 MOTIVAÇÃO

A motivação desta pesquisa está relacionada com o problema de predição de escorregamentos superficiais deflagrados por chuvas em encostas naturais.

Para tal fim, foi escolhida uma área situada no município de Barbosa (Colômbia), pertencente ao Valle de Aburra, marcado pela densificação de suas encostas geralmente de forma desorganizada, onde recorrentemente acontecem movimentos de massa, deixando desde dezenas até milhares de pessoas afetadas. Na Tabela 1.1 observam-se os eventos que tem marcado a cidade nos últimos anos.

Constatou-se que, na maioria desses eventos, a chuva esteve presente dentre os elementos deflagradores, motivo pelo qual se pensou em uma ferramenta que conseguisse, de forma aproximada, determinar variações na poropressão devido à ocorrência de eventos de chuva, e, de posse dessa variação na poropressão e junto com parâmetros de resistência mecânica do solo, calcular um indicativo de ameaça para essa condição de chuva imposta na encosta em estudo.

Tabela 1.1. Eventos trágicos na historia de Medellín, produzidos por deslizamentos de massa. (Isaza-Restrepo, 2011)

Movimento de massa (Classificação segundo Cruden & Varnes, 1996)	Data	Localização	Prejuízos	
			Óbitos	Afetados
Fluxo de lama	18 de Jun. 1927	Rosellon - Envigado	18	26
Fluxo de lama	12 de Jul. 1954	Media Luna-Santa Elena	>100	67
Deslizamentos de detritos	25 de Jun. 1973	La Manguala-S.A. Prado	13	24
Fluxo de lama	29 Sep. 1974	Santo Domingo-Medellin	>70	1500
Fluxo de detritos	20 de Out. 1980	San Antono - Medellin	>18	250
Deslizamento de detritos	23 de Nov. 1984	Santa Mara - Itagui	10	200
Deslizamento de terra	26 de Sep. 1985	Popular 2 - Medellin	6	60
Deslizamento de terra	27 de Sep. 1987	Villatina - Medellin	>500	3000
Fluxo de lama	4 de Feb. 2005	El Barro - Bello	42	60
Deslizamento rotacional complexo	28 de Mai. 2007	La Cruz	8	>60
Deslizamento de detritos	31 de Mai. 2008	El Socorro - Medellin	27	>60
Deslizamento de terras	16 de Nov. 2008	Alto Verde - Medellin	12	>12
Fluxo de terras	5 Dez. 2010	La Gabriela - Bello	85	>130

Modelos para predição de escorregamento em encostas aparecem na literatura (Borga et al., (1998); Iverson, (2000) ;Neaupane & Piantanakulchai (2006); Montrasio & Valentino, (2008); Sassa et al., (2010); Aristizábal et al., (2016)) mas a grande quantidade de variáveis a serem inseridas, a disponibilidade de todas as variáveis para qualquer região e o tempo de processamento e calculo tornam impossível usa-los como sistema de alerta.

Aparecem também na literatura outros modelos para predição de escorregamentos em encostas baseados em RNA (Ni et al. (1996); Neaupane & Achet (2004); Garcia (2004); Yesilnacar & Topal (2005); Ermini et al., (2005); Pradhan & Lee (2010)), mas esses modelos utilizam dentre outros, parâmetros produto de observação geomorfológica, com esses modelos não seria possível obter um indicativo de estabilidade como o fator de segurança.

1.2 HIPÓTESES E OBJETIVOS

A principal hipótese desta tese é que, utilizando a ferramenta computacional conhecida como Redes Neurais Artificiais (RNA) é possível simular de maneira aproximada o processo de infiltração de chuvas e elaborar um sistema de alerta para escorregamentos superficiais deflagrados por chuvas em encostas naturais.

Para isso, propõe-se desenvolver uma metodologia que permita constatar a aplicabilidade das RNA para predição de escorregamentos superficiais deflagrados por chuvas em encostas naturais e avaliar a sua utilização como parte de um sistema de alerta. O modelo neuronal deverá ser capaz de estimar a variação da pressão de poros com a profundidade na encosta sob uma condição de chuva definida e ainda prever a localização do escorregamento.

Para atingir este objetivo geral, propõem-se os seguintes objetivos específicos:

- Treinar, validar e verificar arquiteturas de RNA com variáveis envolvidas no processo de escorregamentos superficiais em encostas, tais como: curva característica solo-água, geometria da encosta, espessura da camada de solo e parâmetros de resistência que representem o comportamento dos solos característicos do local de estudo.
- Implementar o modelo de rede neural como sistema de alerta para escorregamentos superficiais deflagrados por chuvas.
- Fornecer indicativo de estabilidade ou instabilidade de uma determinada encosta no local de estudo sob condição de chuva definida.
- A ferramenta deverá permitir obter mapas de ameaça para o local de estudo, criados a partir da rede neural, sob diferentes cenários de chuvas e variações nas propriedades do solo.

2 REVISÃO DA LITERATURA

2.1 CLASSIFICAÇÃO DOS MOVIMENTOS DE MASSA

A tradução da palavra inglesa “*landslide*” para o português tem gerado expressiva confusão. Ela é utilizada na literatura técnica em língua inglesa para significar “movimento de massa”. Porém, é traduzida muitas vezes como “deslizamento” ou “escorregamento”, limitando-se a palavra a um só tipo de movimento de massa. Como bem é referido por Guzzetti et al., (2012), “*landslide*”, “*mass movement*” e “*slope failure*” podem ser usados como sinônimos. Nesse contexto, “deslizamento” ou “escorregamento” seria a tradução correta de “*Slide*”, como se deduz da classificação de Cruden & Varnes (1996).

O termo deslizamento descreve uma ampla variedade de processos que resultam na movimentação, descendente e ao longo da transversal, dos materiais de formação de uma encosta, incluindo rocha, solo, preenchimento artificial, ou uma combinação destes, sob a ação da gravidade, quando a tensão cisalhante atuante é maior que a tensão resistente da massa deslizante (Cruden & Varnes, (1996); Fabio de Blasio, (2011)). Os materiais podem se movimentar ou cair, derrubando, deslizando, espalhando ou fluindo.

As classificações de movimentos de massa propostas por Varnes (1978), posteriormente modificada por Cruden & Varnes (1996), são os sistemas mais amplamente aceitos na comunidade científica atualmente. Varnes (1978) utiliza como critério principal na sua classificação o tipo de movimento e, em segundo lugar, o tipo de material. Propõe cinco tipos de movimento: quedas (*falls*), tombamentos (*topples*), deslizamentos (*slides*), espalhamentos (*spreads*), escoamentos ou corridas (*flows*); e duas classes de material: rocha e solo, este último subdividido em detritos e terra. Porém, os movimentos de massa podem formar uma falha complexa envolvendo dois ou mais tipos principais de movimento e material, ao mesmo tempo ou durante a vida do movimento, formando subcategorias menos comuns.

Cruden & Varnes (1996) propuseram modificações para a classificação de Varnes (1978). Sua classificação continua com os mesmos cinco tipos de movimentos e os dois tipos de materiais. Para eles, qualquer movimento de massa pode ser classificado e descrito por dois nomes; o primeiro descreve o tipo de movimento e o segundo descreve o material. Além disso, eles consideram dois aspectos mensuráveis: o conteúdo de água (seco, úmido, molhado, muito molhado) e a velocidade, que caracterizam o material e o movimento, respectivamente. Na Tabela 2.1 e Tabela 2.2 apresenta-se o resumo desta classificação.

Tabela 2.1. Resumo da classificação dos movimentos de massa Cruden & Varnes (1996)

Tipo de Movimento	Tipo de Material		
	Rocha	Solos	
		Predominantemente grosso	Predominantemente fino
Quedas	Queda de blocos	Queda de detritos	Queda de solo
Tombamentos	De rocha	De detritos	De solo
Deslizamentos (Escorregamentos)	Rotacionais de rocha	Rotacionais de rocha e solo	Rotacionais de solo
	Translacionais de rocha	Translacionais rocha e solo	Translacionais de solo
Expansões laterais	De rocha	De detritos	De solo
Corridas (Escoamentos)	Rastejo de rochas (creep)	Rastejos e corridas	

Tabela 2.2. Classificação dos escorregamentos segundo a sua velocidade. Cruden & Varnes (1996)

Classe	Descrição	Velocidade (mm/s)
7	Extremamente rápido	
		$5,00 \times 10^3$
6	Muito rápido	
		$5,00 \times 10^1$
5	Rápido	
		$5,00 \times 10^{-1}$
4	Moderado	
		$5,00 \times 10^{-3}$
3	Lento	
		$5,00 \times 10^{-5}$
2	Muito lento	
		$5,00 \times 10^{-7}$
1	Extremamente lento	

A seguir, são apresentadas as descrições gerais dos principais movimentos de terra enunciados nas tabelas acima.

2.1.1 QUEDAS

As quedas são movimentos bruscos de massas de materiais geológicos, tais como pedras e pedregulhos, provenientes de encostas íngremes ou falésias.

A separação ou movimento ocorre ao longo de discontinuidades, tais como fraturas, juntas, e planos de acamamento. O movimento é de muito rápido a extremamente rápido, ocorre por queda livre, sendo fortemente influenciado pela gravidade, resistência mecânica, e pela presença de água intersticial Varnes (1978)

2.1.2 TOMBAMENTOS

Consiste na rotação de uma ou mais unidades de material sobre um ponto, sob a ação da gravidade ou por forças exercidas por outras unidades ou por fluidos em fissuras.

2.1.3 DESLIZAMENTOS

Deslizamento ou escorregamento é um movimento descendente de uma massa de solo ou rocha, que ocorre predominantemente ao longo de uma superfície de falha ou de uma delgada zona de deformação e de cisalhamento intenso.

No sistema de Varnes (1978) os deslizamentos são classificados segundo a forma da superfície de falha em translacionais e rotacionais. Os escorregamentos translacionais podem ser planares ou em cunha. No entanto, as superfícies de ruptura são geralmente mais complexas e apresentam segmentos planos e curvos.

Estes tipos de movimentos, quando deflagrados por chuvas, são geralmente denominados deslizamentos superficiais planares (*soil slip*), e caracterizam-se pela espessura muito menor do que o comprimento do movimento (0,3-2m) e superfície de falha subparalela à superfície da encosta (Anderson & Sitar, 1995).

Embora o movimento seja considerado como rápido, usualmente apresenta os primeiros sinais de deslocamento mediante fissuras na parte superior.

2.1.4 EXPANSÕES LATERAIS

Geralmente ocorrem em encostas com declividades muito suaves ou terrenos planos. Nas expansões o movimento dominante é o acomodamento lateral por fraturas de cisalhamento ou tensão.

É a extensão de uma massa de solo ou rocha coesivo combinado com uma subsidência geral da massa fraturada de material coesivo sobre uma camada de material fraco. A falha é causada, geralmente, por liquefação e por movimentos de solo rápidos, como os experimentados durante um terremoto.

2.1.5 CORRIDAS

São deformações ou movimentos contínuos, frequentemente sem apresentar uma superfície definida ao longo da qual a movimentação ocorra.

A distribuição de velocidades no deslocamento da massa lembra um fluido viscoso. Se os movimentos são lentos denominam-se rastejos, e, se rápidos, denominam-se corridas. As

corridas de detritos e lama estão entre os fenômenos mais destrutivos da natureza, em que o material com alto teor de umidade perde coesão e ganha velocidade no caminho de descida (Cruden & Varnes, 1996). Na Figura 2.1 podem ser observados os esquemas dos deslizamentos descritos acima.

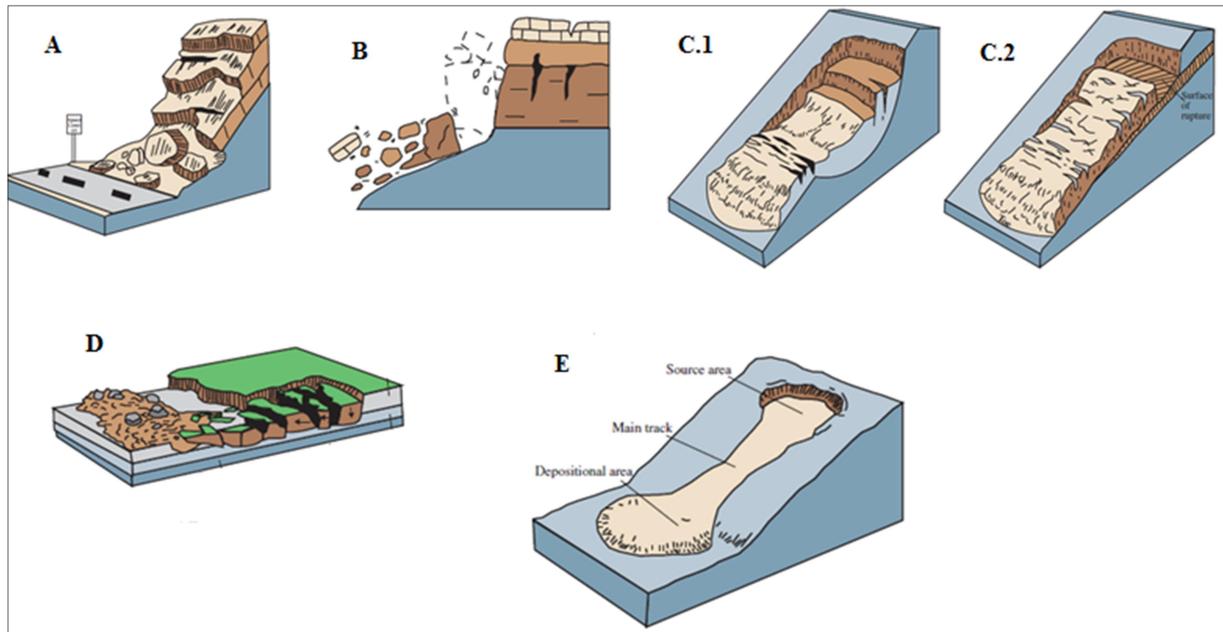


Figura 2.1.A:Quedas, B:Tombamentos, C.1:Deslizamento rotacional, C.2: deslizamento translacional, D: expansão lateral, E: corridas. (USGS, 2004)

2.2 CAUSAS DOS MOVIMENTOS DE MASSAS

Os movimentos de massas são um componente crucial do ciclo geológico da terra. São continuamente gerados pela gravidade e pelo fluxo de água, impulsionado pela gravidade, em direção ao nível de base dos taludes. Os movimentos de massa representam a componente de erosão direta da gravidade. Há evidências crescentes, por meio de dados de magnitude-frequência, que deslizamentos maiores fornecem mais sedimentos aos sistemas fluviais ao longo do tempo do que movimentos menores, de modo que eventos grandes dominem o suprimento de sedimentos das cadeias hídricas de uma região (Shroder et al., 2015)

O perigo de qualquer processo natural pode ser expresso em função da sua magnitude e do valor anual de probabilidade de ocorrência em uma região específica (Korup & Clague, 2009). No caso dos deslizamentos de massas, Malamud et al., (2004) apresenta na Figura 2.2 o gráfico a seguir:

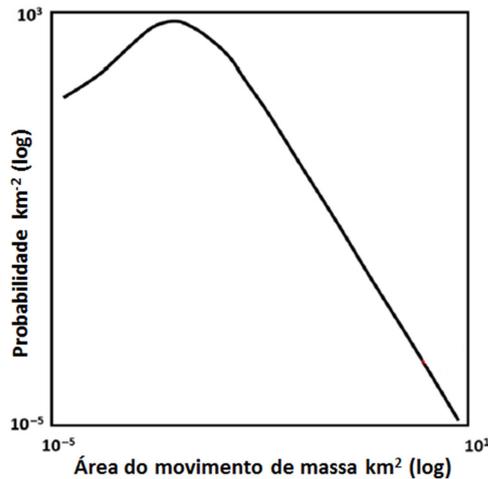


Figura 2.2. Densidade de probabilidade de movimentos de massa (Malamud et al., 2004) modificado

Conforme a figura 2.2, a distribuição de probabilidade de movimentos de massa de uma montanha é limitada porque a extensão física da mesma limita a área de deslizamentos de terra que podem ocorrer (Shroder et al., 2015)

Dentre os agentes causadores de escorregamentos em geral, pode-se dizer que, no caso de solos não saturados, o principal é a água (chuva, lançamento de águas servidas, ruptura de tubulações, etc.).

No Brasil e na Colômbia não é diferente: a principal causa dos escorregamentos é a água, que pode atuar como agente preparatório e deflagrador dos escorregamentos. Os escorregamentos podem ocorrer em solos não saturados ou saturados (Camapum de Carvalho et al., 2012). Em ambas as condições, a água comanda o processo de instabilidade.

A redução da sucção, a saturação do solo ou a elevação do nível freático dependem da interação do solo com as condições climáticas. Em condições normais, a infiltração da água da chuva é a principal fonte de água das encostas. Em encostas ocupadas, pode haver lançamento de águas servidas e, em outros casos, vazamentos de tubulações de água ou esgoto, os quais também podem contribuir para infiltração. O clima tropical contribui para formação de solos espessos, além de apresentar elevados índices pluviométricos.

Segundo Soeteres & Van Westen (1996), os movimentos de massa são o produto do enfraquecimento progressivo das propriedades mecânicas dos materiais das encostas por processos naturais, tais como o intemperismo, os movimentos tectônicos e as atividades antrópicas. O USGS (2004) propõe uma classificação baseada em causas geológicas e morfológicas:

- **Causas geológicas:** Materiais frágeis ou sensíveis, materiais expostos, materiais cisalhados, descontinuidades com orientação adversa, contraste de permeabilidade e/ou rigidez de materiais.
- **Causas morfológicas:** levantamento tectônico ou vulcânico, recuperação glacial, erosão fluvial, erosão subterrânea (solução, pipping), remoção da vegetação (por incêndios ou secas), intemperismo por ciclos de congelamento e descongelamento; inchamento e encolhimento.

Usualmente não é possível apontar uma única causa que agiu sozinha e resultou na causa deflagradora. Na maioria dos casos, diversas ‘causas’ acontecem simultaneamente, de modo que tentar decidir finalmente qual foi a deflagradora não seria somente difícil como também tecnicamente incorreto (Sowers, 1979).

As características que afetam a ocorrência de deslizamento de terra não são fixas, mas sim, constituem interações dinâmicas que podem flutuar em minutos ou segundos (Walker & Shiels, 2013)

2.3 ESTABILIDADE DE TALUDES EM SOLOS

A estabilidade de obras de engenharia é definida usualmente em termos determinísticos, através de um FS. A escolha do método de análise mais adequado é um aspecto relevante a ser considerado, sendo função tanto da importância da obra quanto da qualidade dos dados disponíveis.

Os métodos para análise de estabilidade de taludes em solo incluem equações simples, gráficos, planilhas de cálculo e softwares especializados. Em muitos casos, mais de um método pode ser empregado para avaliar a estabilidade de um talude particular. A precisão do resultado depende das condições específicas do talude e do método empregado para análise (Duncan & Wright, 2014)

A gravidade tenderia a esticar as encostas, se não fosse pelas forças de coesão e fricção das rochas e dos solos. No entanto, as condições de estabilidade podem mudar devido a ajustes temporários de equilíbrio ou devido a perturbações externas. Neste caso, um deslizamento de terra pode ser desencadeado (de Blasio, 2011)

Em casos de taludes naturais, a análise da estabilidade pode fazer uso também de técnicas probabilísticas, considerando que a escolha dos parâmetros mais relevantes está inevitavelmente sujeita a incertezas. Assim, o cálculo da segurança de um talude inclui erros

e/ou imprecisões que são relativos não só aos parâmetros relevantes ao problema, mas também ao método de análise adotado (GeoRio, 1999).

Vários métodos para o cálculo de estabilidade de taludes aparecem na literatura (Bishop, 1955; Morgenster & Price, 1965; Spencer, 1967; Janbu, 1968; Duncan 1996). Entretanto, existe pouca investigação a respeito do zoneamento de estabilidade de taludes, devido a dificuldades no processamento de dados espaciais, tais como: ângulo do talude, elevação, aspecto, etc.

Vários autores, como Cho & Lee, (2002), Muntohar & Liao, (2010), utilizam, na previsão de deslizamento de taludes, o modelo simplificado de talude infinito, que inclui variáveis do solo estáticas no tempo (C: coesão, γ : peso específico, ϕ : ângulo de atrito, α : inclinação do talude, h: altura do talude), e adotam a envoltória de resistência proposta por Fredlund et al., (1978) para solos não saturados. Com o método de talude infinito é possível abordar a estabilidade ou instabilidade de um talude fazendo uma relação entre as forças atuantes e resistentes, como se mostra na equação 2.1.

$$FS = \frac{\text{forças resistentes}}{\text{forças atuantes}} = \frac{f(c', \phi, \gamma, \dots)}{f(\text{peso talude, carregamentos externos, forças de infiltração, etc.})} \quad (2.1)$$

Um valor $FS > 1$ indica estabilidade, enquanto que $FS < 1$ implica instabilidade. Assim, a transição entre a estabilidade e o colapso pode ser vista matematicamente como uma diminuição no fator de segurança para valores abaixo da unidade.

Uma vez definida a distribuição da sucção e os parâmetros de resistência, o cálculo do fator de segurança é uma tarefa simples. Mas, para se ter representatividade da condição real, é preciso conhecer a distribuição espacial e temporal das variáveis. O cálculo de estabilidade deixa de ser uma análise única para um talude. Além disso, depende fundamentalmente da interação do talude com as condições climáticas associadas com a infiltração da água da chuva, a variação do nível freático ou outro mecanismo que altere a distribuição de poropressão no solo.

As ferramentas de geoinformação tornaram-se essenciais para a avaliação de ameaça, vulnerabilidade e risco de movimentos de massa. À escala grande ($< 1:10000$), os modelos determinísticos são mais utilizados para determinar fatores de segurança e modelos dinâmicos para retratar as trajetórias de movimentos de massas. Quando combinado com métodos probabilísticos, relacionados à variabilidade de dados de entrada e períodos de retorno de

eventos desencadeantes, a probabilidade de falha pode ser obtida (abordagens probabilísticas) (van Westen et al., 2006).

Em zoneamento de estabilidade de taludes duas classes de métodos podem ser reconhecidas: métodos estatísticos e determinísticos.

Um dos métodos estatísticos, a estatística multivariada, analisa a relação entre a ocorrência de um escorregamento e os fatores relacionados (profundidade da camada do solo, resistência do solo, ângulo do talude, vegetação, etc.) e cria um índice de avaliação integrada para uma área piloto e logo prevê o risco de escorregamentos para uma área vizinha.

Os métodos determinísticos analisam o equilíbrio mecânico de um potencial bloco deslizante e calculam o fator de segurança do talude. Por outro lado, os métodos estatísticos não têm significado mecânico, ao contrário dos métodos determinísticos, os quais consideram o equilíbrio de forças aplicadas no talude (forças atuantes e forças resistentes). São métodos bons e razoáveis para um local específico. Mas, utilizar o método determinístico em uma investigação de zoneamento regional de estabilidade de taludes pode ser difícil ou algumas vezes impossível, devido à dificuldade na obtenção, revisão e processamento de um pacote grande de dados espaciais, identificação de superfícies de deslizamento e monitoramento das pressões de poros. Um tópico importante de estudo nos últimos anos é a criação de mapas de risco em áreas montanhosas, partindo de uma limitada investigação *in-situ* (Zhou et al., 2003).

Para obter mapas de risco quantitativos, o primeiro requisito essencial é realizar uma avaliação quantitativa da ameaça. A maioria dos mapas de ameaça ainda é de natureza qualitativa e se concentram basicamente na determinação da susceptibilidade, que pode ser vista como uma indicação relativa da probabilidade espacial. A probabilidade espacial ou susceptibilidade ao deslizamento pode ser obtida usando diferentes abordagens analíticas.

A avaliação estatística do risco de movimentos de massa tornou-se muito popular, especialmente com o uso de Sistemas de Informação Geográfica (SIG) e a possibilidade de aplicar técnicas de integração de dados que tenham sido desenvolvidos em outras disciplinas.

Isso requer um mapa de inventário de deslizamento que é usado em combinação com uma série de fatores ambientais, e baseia-se no pressuposto de que os deslizamentos de terra provavelmente ocorrerão sob as mesmas condições que ocorreram no passado recente.

No entanto, as condições do terreno mudam após a ocorrência de um movimento de massa e, portanto, muitos dos fatores ambientais, como o ângulo da inclinação ou o uso da terra, são diferentes após a ocorrência do movimento de massa (van Westen *et al.*, 2006).

Além disso, a combinação específica de fatores ambientais é bastante diferente para diferentes tipos de movimentos de massas.

Na avaliação de susceptibilidade ao movimento de massas, o uso da opinião de especialistas é cada vez mais considerado como "subjetivo", tendo-se buscado sua substituição por algoritmos computacionais "objetivos" (métodos baseados no SIG). A avaliação estatística da susceptibilidade ao movimento de massas geralmente é mais focada na ferramenta do que nos dados de entrada e frequentemente envolve uma simplificação extrema dos fatores de controle dos movimentos de massas.

Na Figura 2.3 observa-se um esquema dos métodos de zoneamento de ameaça de movimentos de massas.

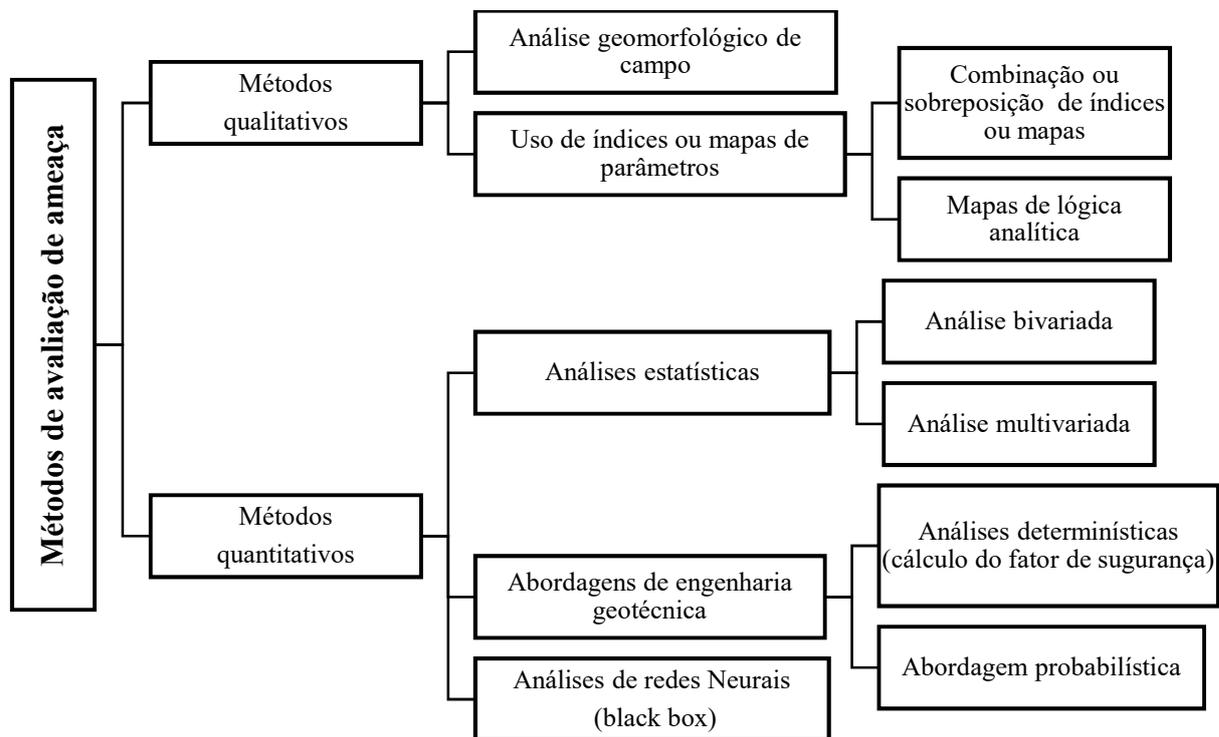


Figura 2.3. Classificação proposta de métodos de avaliação de ameaça de terra (modificado Aleotti & Chowdhury, 1999)

Os modelos baseados na estatística fundamentam-se na análise das relações entre fatores e a distribuição de movimentos de massas passados e presentes. Usam-se várias técnicas estatísticas bivariadas e multivariadas. A técnica bivariada é conceitualmente (mas não operacionalmente) simples. Atribui relação probabilista entre fatores ambientais relevantes e a ocorrência de movimentos de massa numa região. Leva em conta a frequência com a que se apresentam os deslizamentos, seja em número ou percentagem da área, para obter a probabilidade dependente dos eventos prévios. O modelo estatístico multivariado é baseado na hipótese de que os fatores que causaram a instabilidade no passado gerarão deslizamento no futuro (Ramos, 2003).

Nos métodos quantitativos encontra-se a técnica baseada em análises de redes neurais, considerada um modelo “caixa preta” (Aleotti & Chowdhury, 1999). Uma vantagem importante do método das RNAs é que não depende do tipo de distribuição estatística dos dados, como as análises estatísticas bivariadas e multivariadas, viabilizando os trabalhos feitos por Biswajeet & Saro (2007) e Caniani et al., (2008), nos quais mediante uma RNA treinada com imagens de satélite de cobertura e uso do solo, declividade, aspecto, dados de chuva, curvatura e distância de drenagem obtiveram mapas de ameaça para seus respectivos locais de estudo.

Os modelos fundamentados na física ou na geotecnia utilizam as leis físicas que controlam a instabilidade – por exemplo, poropressões, geometria do talude, parâmetros de resistência – e obtém-se o grau de estabilidade por um método de estabilidade de taludes convencional. O resultado fornecido pelo modelo é o FS, que relaciona as tensões que se opõem ao movimento com as tensões que o promovem.

Mediante esse modelo, é possível identificar os fatores detonantes de movimentos de massa. Possui a desvantagem de precisar de grande quantidade de dados cuja obtenção não é economicamente viável para regiões de extensão significativa. Adicionalmente, existem vários mecanismos de ruptura (em rochas, por exemplo) que não são facilmente modelados. No entanto, permitem calcular de forma quantitativa a contribuição dos diferentes fatores desestabilizadores.

Os modelos para avaliar a estabilidade podem calcular o fator de segurança em 1, 2 ou 3 dimensões. O modelo unidimensional (também chamado de talude infinito) calcula a estabilidade em cada ponto, sem considerar as forças resultantes nas áreas adjacentes. Alguns modelos de análise de estabilidade em 2 dimensões fazem os cálculos ao longo de perfis, dividindo a superfície de ruptura em fatias e fazendo o equilíbrio interno de cada uma (Duncan et al., 2014).

Esses métodos, conhecidos como equilíbrio limite, diferenciam-se uns dos outros pelas hipóteses que fazem para calcular as forças entre as fatias. Outros métodos determinísticos utilizados para avaliar a estabilidade de um talude individual em 2-D são os que utilizam os elementos finitos, podendo-se obter tensões e deformações em diferentes pontos da massa do solo. Os modelos em três dimensões calculam a estabilidade do corpo do deslizamento como um todo.

Em conjunto com os SIG, o modelo físico mais usado, pela simplicidade das equações, é o método do talude infinito (Duncan et al, 2014). A utilização desse modelo é apropriada para o caso de movimentos superficiais governados pela topografia, com planos de ruptura

paralelos à superfície do terreno, ou alguns deslizamentos profundos. No entanto, não é recomendável para áreas com variados mecanismos de ruptura. Não é compensatório o uso de SIG com mapas detalhados para utilizar um modelo simplificado que forneça como resultado estimativas grosseiras (Dai et al., 2002).

Algumas metodologias utilizam a ferramenta de análise de vizinhança do SIG, que permite analisar os pixels vizinhos ao redor do ponto central. Com essa técnica podem ser simuladas as trajetórias dos deslizamentos (especialmente importantes no caso de fluxo de detritos) e a resposta hidrológica às chuvas (Dai et al., 2002)

Atualmente, os modelos geotécnicos são úteis apenas em áreas de extensão limitada, porque é difícil coletar dados geotécnicos com uma resolução adequada. Além disso, muitas das variáveis físicas que são necessárias para a execução desses modelos geralmente não estão disponíveis, e sua aquisição é muitas vezes muito dispendiosa (Yesilnacar & Topal, 2005).

2.4 INTELIGÊNCIA ARTIFICIAL

É o ramo da ciência que estuda o conjunto de paradigmas que pretendem justificar como um comportamento inteligente pode emergir de implementações artificiais, em computadores. O que pode ser considerado um sistema inteligente é, no entanto, ainda bastante polêmico (Garcia, 2004).

Um subterfúgio permite identificar sistemas inteligentes de forma indireta. Considera-se um programa de computador inteligente quando este realiza uma tarefa que, se fosse feita por um ser humano, seria considerada inteligente (Bauschpiess, 2002).

Sistemas complexos não devem ser confundidos com sistemas inteligentes. Assim, um robô manipulador que aplica pontos de solda na carroçaria de veículos, apesar de realizar uma sequência complexa de movimentos, não é considerado inteligente. Este robô apenas repete uma sequência de movimentos previamente armazenada. Falta a esse sistema a capacidade de se adaptar a situações completamente novas. Uma das características de sistemas inteligentes é justamente a capacidade de aprender e se adaptar a um ambiente desconhecido, ou a uma situação nova (Garcia, 2004).

Exemplos de sistemas inteligentes são os sistemas especialistas, a lógica fuzzy e as RNAs. O primeiro trabalha com a chamada lógica simbólica (não numérica); já os outros dois, com a lógica conexionista. A abordagem conexionista considera ser virtualmente impossível transformar em algoritmos diversas tarefas que a mente humana executa com facilidade, como, por exemplo, reconhecer rostos ou compreender e traduzir línguas. Por

esses motivos, o computador deve tentar reproduzir a capacidade do cérebro de se auto organizar e aprender. As RNAs imitam a fisiologia do cérebro, enquanto a lógica difusa imita a psicologia (Bauschpiess, 2002).

2.5 REDES NEURAIAS ARTIFICIAIS (RNAs)

Nos últimos anos, as RNAs, principais representantes da área conexionista da Inteligência Artificial, têm sido aplicadas nas mais diversas áreas do conhecimento. Uma rede neural é extremamente útil para representar processos físicos quando modelos baseados na física do fenômeno podem resultar em modelos matemáticos de grande complexidade analítica e/ou numérica. As RNAs utilizam dados medidos diretamente de um processo em estudo representando o fenômeno em condições reais. São capazes de lidar com problemas não lineares, resolver situações não vistas em seu processo de treinamento (ajuste do modelo), obter as relações entre atributos de entrada e saída como uma função entre esses parâmetros, na qual parâmetros de entrada são mapeados em parâmetros de saída. Além disso, possuem um alto desempenho computacional quando se encontram em operação (Zárate et al., 2008)

RNAs são sistemas paralelos distribuídos compostos por unidades de processamento simples (neurônios ou nodos) que calculam determinadas funções matemáticas (normalmente não lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais.

Na maioria dos modelos, essas conexões estão associadas a pesos, os quais armazenam o conhecimento representado no modelo e servem para ponderar a entrada recebida por cada neurônio da rede. O funcionamento dessas redes é inspirado em uma estrutura física concebida pela natureza: o cérebro humano (Braga et al, 2000).

Embora as redes neurais apresentem algumas semelhanças com o cérebro humano, elas não pretendem modelá-lo. O cérebro humano é muito mais complexo e, infelizmente, uma grande parte das suas funções cognitivas é ainda hoje desconhecida.

Segundo Garcia (2004), pela forma como é realizado o processamento da informação, as redes neurais naturais e artificiais apresentam as seguintes características comuns: aprendizado e adaptação, generalização, processamento paralelo, estabilidade, armazenamento associativo de informação, processamento espaço-temporal de informação.

Elas reagem ao treinamento por inserção de dados, de modo a alterar o seu estado inicial, coisa que nenhum algoritmo convencional faz: elas podem aprender (Lees,1996).

2.5.1 PRINCIPAIS ARQUITETURAS DE RNAs

A definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Redes com uma única camada de nós MCP, por exemplo, só conseguem resolver problemas linearmente separáveis. Fazem parte da definição da arquitetura os seguintes parâmetros: número de camadas da rede, número de nós em cada camada, tipo de conexão entre os nós e tipologia da rede. Alguns exemplos de arquiteturas de RNA são apresentados na Figura 2.4

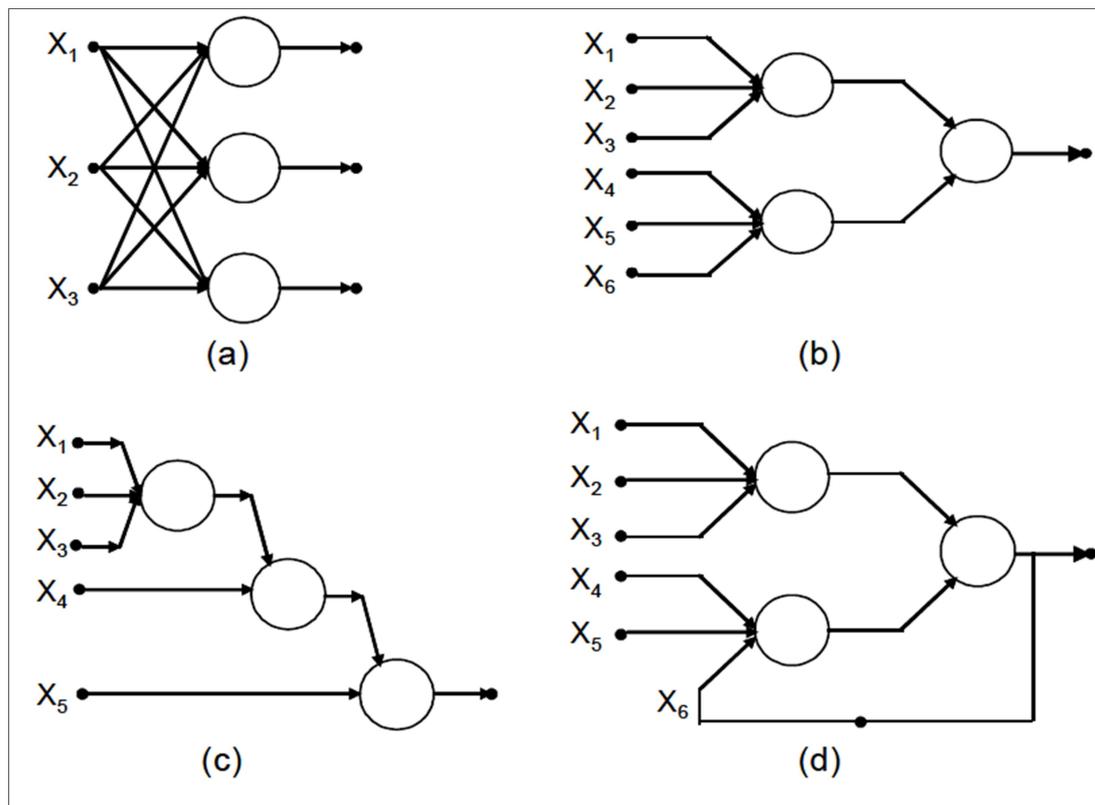


Figura 2.4. Principais arquiteturas de RNAs. Modificado de (Braga et al, 2000).

Quanto ao número de camadas, pode-se ter:

1. Redes de camada única: só existe um nó entre qualquer entrada e qualquer saída da rede. Figura 2.4 (a)
2. Redes de múltiplas camadas: existe mais de um neurônio entre alguma entrada e alguma saída da rede. Figura 2.4 (b), (c) e (d).

Os nós podem ter conexões do tipo:

1. *Feedforward*, ou acíclica: a saída de um neurônio na i -ésima camada da rede não pode ser usada como entrada de nodos e camadas de índice menor ou igual a 1. Figura 2.4 (a), (b) e (c).
2. Redes cuja saída final (única) é ligada às entradas. Elas comportam-se como autômatos reconhecedores de cadeias, onde a saída que é realimentada fornece o estado do autômato. Figura 2.4 (d).

As RNAs podem também ser classificadas quanto à sua conectividade:

1. Redes fracamente (ou parcialmente) conectadas. Figura 2.4 (b), (c) e (d).
2. Rede completamente conectada. Figura 2.4 (a).

2.5.2 NEURÔNIOS BIOLÓGICOS E ARTIFICIAIS

Os neurônios biológicos são divididos em três secções: *o corpo da célula*, os *dendritos* e o *axônio*, cada um com funções específicas, porém complementares. Os dendritos têm por função receber as informações – ou *impulsos nervosos* – oriundas de outros neurônios, e conduzi-las até o corpo celular. Ali, a informação é processada, e novos impulsos são gerados. Esses impulsos são transmitidos a outros neurônios, passando através do axônio até os dendritos dos neurônios seguintes. O ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é chamado de *sinapse*.

É pelas sinapses que os nodos se unem funcionalmente, formando redes neurais. As sinapses funcionam como válvulas, e são capazes de controlar a transmissão de impulsos – isto é, o fluxo da informação – entre os nodos na rede neural. O efeito das sinapses é variável, e é esta variação que dá ao neurônio capacidade de adaptação. Os sinais oriundos dos neurônios *pré-sinápticos* são passados para o corpo do neurônio pós-sináptico, onde são comparados com os outros sinais recebidos pelo mesmo.

Se o percentual em um intervalo curto de tempo é suficientemente alto, a célula “dispara”, produzindo um impulso que é transmitido para as células seguintes (nodos *pós-sinápticos*). Esse sistema simples é responsável pela maioria das funções realizadas pelo nosso cérebro. A capacidade de realizar funções complexas surge com a operação em paralelo de todos os 10^{11} nodos de nosso cérebro. (Braga et al, 2000).

Na Figura 2.5, apresenta-se o modelo artificial de um neurônio típico em RNA, o qual inclui um sinal adicional *bias* (b) que favorece ou limita a possibilidade de ativação do neurônio. O processo sináptico é representado pelos *pesos* (w) que amplificam cada um dos sinais recebidos. A chamada função de ativação (f) modela a forma como o neurônio responde ao nível de excitação, limitando e definindo a saída da rede neural.

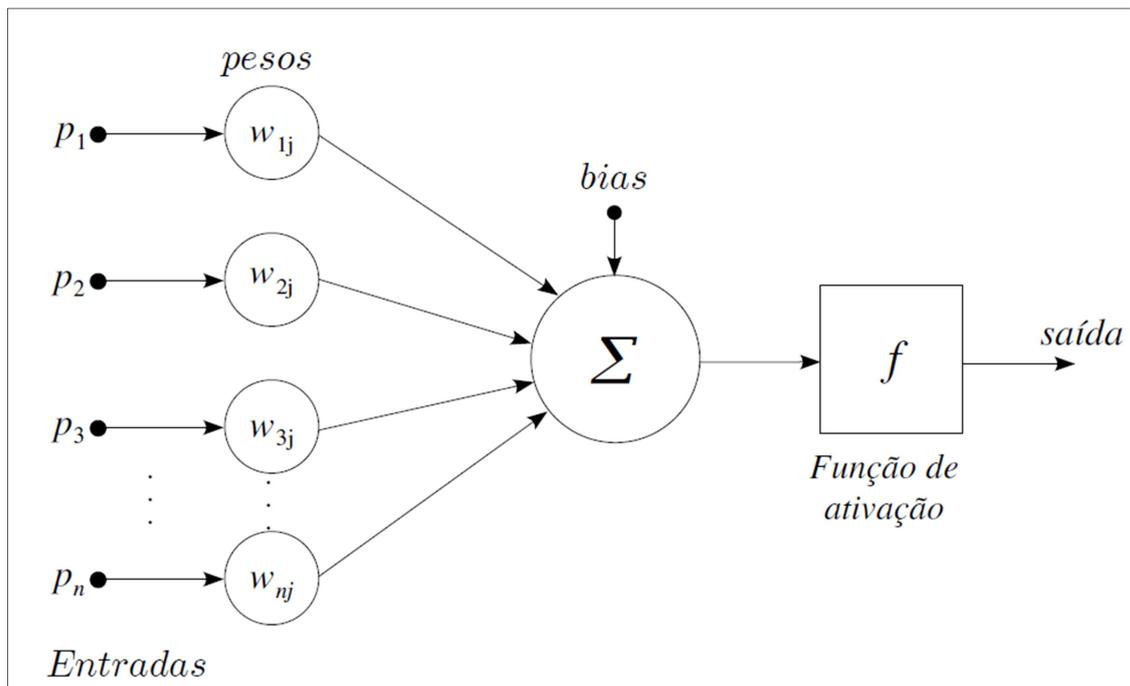


Figura 2.5. Modelo artificial de um neurônio (Haykin, 2001)

2.5.3 FUNÇÕES DE ATIVAÇÃO

A função de ativação pode ter diferentes representações. Os três tipos básicos de função de ativação são: limiar, linear e sigmoide (Kasabov, 1998), explicadas como:

- Função limiar: se o valor de entrada supera certo limiar o neurônio se ativa; caso contrário, permanece inativo.
- Função linear: o valor de ativação aumenta linearmente à medida em que aumenta o valor do sinal de entrada; porém, a partir de certo limiar, a saída fica saturada atingindo e permanecendo no seu valor máximo.
- Função sigmoide: é uma função de transformação não linear com forma de S, que apresenta as seguintes características:
 - a) Limitada, ou seja, seus valores estão restringidos entre duas fronteiras;
 - b) Monotonamente crescente;
 - c) Contínua e suave, ou seja, diferenciável ao longo de todo o seu domínio.

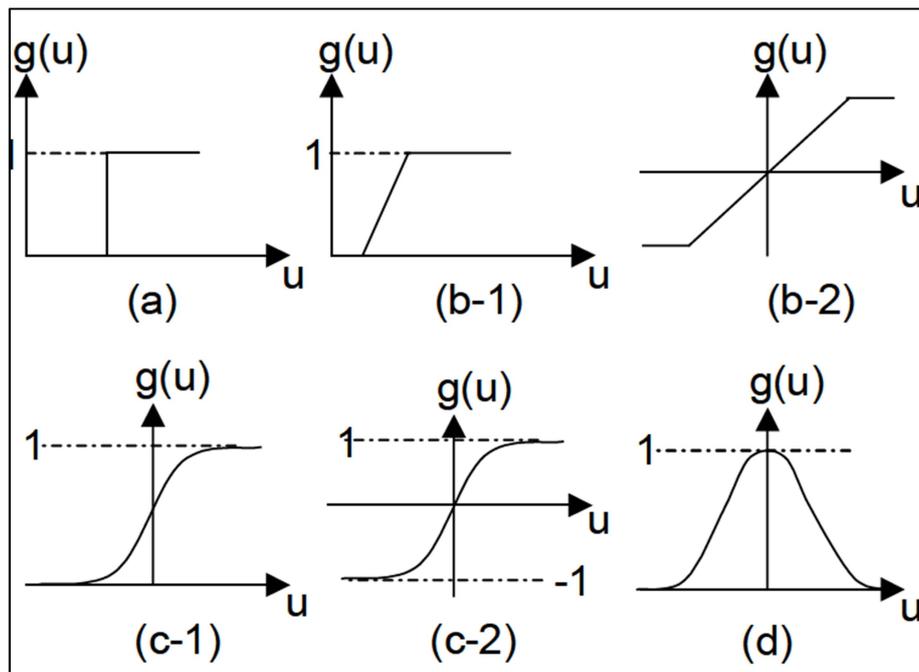


Figura 2.6. Funções de ativação mais usadas: a)limiar, b-1 e b-2)linear, c)sigmoide: logística c-1), tangente hiperbólica c-2), Gaussiana c-3). (Martinez, 2006)

2.5.4 PROCESSO DE APRENDIZAGEM

Aprendizagem é um processo pelo qual os parâmetros de uma rede neural são ajustados através de uma forma continuada de estímulo pelo ambiente no qual a rede está operando, sendo o tipo específico de aprendizagem realizada definido pela maneira particular como ocorrem os ajustes realizados nos parâmetros.

A propriedade que é de importância primordial para uma rede neural é a sua habilidade de *aprender* a partir de seu ambiente e de *melhorar* o seu desempenho a través da aprendizagem. A melhoria do desempenho ocorre com o tempo de acordo com alguma medida preestabelecida. Uma rede neural aprende sobre o seu ambiente através de um processo iterativo de ajustes aplicados a seus pesos sinápticos e níveis de bias. Idealmente, a rede se torna mais instruída sobre o seu ambiente, após cada iteração do processo de aprendizagem (Haykin, 1999).

Uma rede neural deve passar por uma etapa de aprendizagem, em que é entregue (etapa entrada) a ela um conjunto de dados que descrevem uma situação; ela extrai as características dos dados fornecidos (etapa oculta) e consegue reproduzir (etapa saída) respostas corretas, ou muito aproximadamente corretas para qualquer outro caso. Na Figura 2.7 observa-se o processo de aprendizagem de uma rede neural.

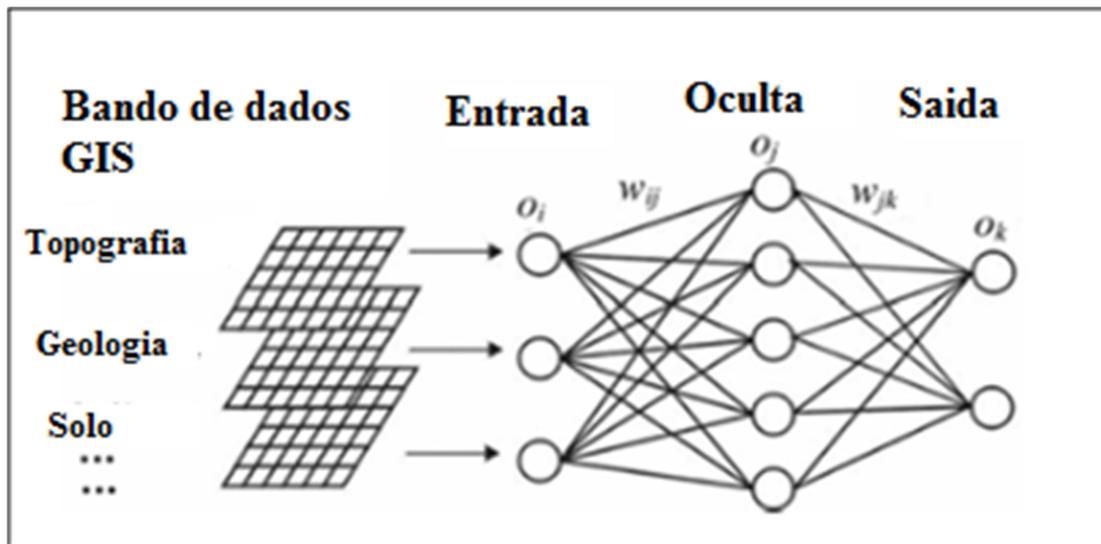


Figura 2.7. Processo de aprendizagem de uma RNA (Biswajeet & Saro, 2007)

O processo de aprendizagem é feito a partir de algoritmo de aprendizagem, onde os pesos sinápticos da rede são modificados de uma forma ordenada para alcançar o resultado desejado. A partir da informação contida em pares de entrada e saídas, contidas em um banco de dados, as RNAs devem “aprender” e generalizar o conhecimento contido nas amostras, de forma a responder adequadamente quando entradas não presentes no conjunto de treinamento forem apresentadas a rede.

Isto é possível devido ao fato de que a formulação é baseada numa representação (simplificada) de uma rede real de neurônios. Dessa forma, problemas relacionados a reconhecimento de padrões podem ser solucionados através da implementação e uso adequados desta técnica.

A capacidade de *aprender* através de exemplos e de *generalizar* a informação aprendida é, sem dúvida, o atrativo principal da solução de problemas através de RNAs. A generalização, que esta associada à capacidade de a rede aprender através de um conjunto reduzido de exemplos e posteriormente dar respostas corretas para dados não conhecidos, é uma demonstração de que a capacidade das RNAs vai muito além de simplesmente mapear relações de entrada e saída. As RNAs são capazes de extrair informações não apresentadas de forma explícita através dos exemplos. Não obstante, as RNAs são capazes de atuar como mapeadores universais de funções multivariáveis, com custo computacional que cresce apenas linearmente com o número de variáveis. Outra característica importante é a capacidade de auto-organização e de processamento temporal, que faz das RNAs uma ferramenta

computacional extremamente poderosa e atrativa para a solução de problemas complexos. (Braga et al, 2000).

2.5.5 REDES MULTI LAYER PERCEPTRON (MLP)

As redes de uma só camada resolvem apenas problemas linearmente separáveis. A solução de problemas não linearmente separáveis passa pelo uso de redes com uma ou mais camadas intermediárias, ou ocultas. No entanto, a utilização de um grande número de camadas intermediárias não é recomendada (Braga et al, 2000), pois, cada vez que o erro medido durante o treinamento é propagado para a camada anterior, ele se torna menos útil ou preciso. A única camada que tem uma noção precisa do erro cometido pela rede é a camada de saída. A última camada intermediária recebe apenas uma estimativa sobre o erro. A penúltima camada intermediária, uma estimativa da estimativa, e assim por diante.

Com relação ao número de nós nas camadas intermediárias, este é em geral definido empiricamente.

O algoritmo mais conhecido para o treinamento deste tipo de redes é o algoritmo *back-propagation* o qual utiliza pares (entrada, saída desejada) para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, sendo que cada fase percorre a rede em um sentido. Essas duas fases são chamadas de fase *forward* e fase *backward*. A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entrada. A fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões.

A fase *forward* envolve os seguintes passos:

1. A entrada é apresentada à primeira camada da rede, a camada C^0 .
2. Para cada camada C^i a partir da camada de entrada:
Após os nodos da camada C^i ($i > 0$) calcularem seus sinais de saída, estes servem como entrada para a definição das saídas produzidas pelos nodos das camadas C^{i+1}
3. As saídas produzidas pelos nodos da última camada são comparadas às saídas desejadas.

A fase *backward* envolve as etapas listadas a seguir:

1. A partir da última camada, até chegar à camada de entrada:
Os nós da camada atual ajustam seus pesos de forma a reduzir seus erros.

O erro de um nó das camadas intermediárias é calculado utilizando os erros dos nós da camada seguinte conectados a ele, ponderados pelos pesos das conexões entre eles.

O algoritmo *back-propagation* é baseado na regra delta proposta por Widrow & Hoff (1960), sendo chamada de regra delta generalizada. Esse algoritmo propõe uma forma de definir o erro dos nodos das camadas intermediárias, possibilitando o ajuste de seus pesos. Os ajustes dos pesos são realizados utilizando-se o método do gradiente. Na literatura de análise numérica, a regra delta generalizada é conhecida como o “método de bola pesada”. Dito algoritmo procura minimizar o erro obtido pela rede, ajustando pesos para que eles correspondam às coordenadas dos pontos mais baixos da superfície de erro. Para isto, ele utiliza um método de gradiente descendente.

O gradiente de uma função está na direção e sentido em que a função tem taxa de variação mínima. Isto garante que a rede caminha na superfície na direção que vai reduzir mais o erro obtido. Para superfície simples, esse método certamente encontra a solução com erro mínimo. Para superfícies mais complexas, essa garantia não mais existe, podendo levar o algoritmo a convergir para mínimos locais. O algoritmo *back-propagation* fornece uma aproximação da trajetória no espaço de pesos calculados pelo método do gradiente descendente.

Um dos problemas enfrentados no treinamento de redes MLP diz respeito à definição de seus parâmetros. A seleção dos parâmetros de treinamento do algoritmo *back-propagation* é um processo tão pouco compreendido que é muitas vezes chamado de “magia negra”. Pequenas diferenças nesses parâmetros podem levar a grandes diferenças tanto no tempo de treinamento quanto na generalização obtida. Não é raro encontrar na literatura, para um mesmo problema, utilizando o mesmo método de treinamento, tempos de treinamento que diferem em uma ou mais ordens de magnitude (Haykin, 1999).

Uma dúvida que surge naturalmente diz respeito a quando parar de treinar a rede. Existem vários métodos para a determinação do momento em que o treinamento deve ser encerrado. Estes métodos são chamados de *critérios de parada*. Os critérios de parada mais utilizados são (Braga et al, 2000):

1. Encerrar o treinamento após N ciclos.
2. Encerrar o treinamento após o erro quadrático médio ficar abaixo de uma constante.

3. Encerrar o treinamento quando a porcentagem de classificações corretas estiver acima de uma constante.
4. Combinação dos métodos acima.

Embora o anterior possa sugerir o contrário, o algoritmo *back-propagation* apresenta uma série de dificuldades ou deficiências que desestimulam uma maior disseminação de seu uso. O principal problema diz respeito à lentidão do algoritmo para superfícies mais complexas. Uma forma de minimizar este problema é considerar efeitos de segunda ordem para gradiente descendente. Não é raro o algoritmo convergir para mínimos locais, os quais são pontos na superfície de erro que apresentam uma solução estável, embora sejam a saída correta. Algumas técnicas são utilizadas tanto para acelerar o algoritmo quanto para reduzir a incidência de mínimos locais:

- Utilizar taxa de aprendizagem decrescente
- Adicionar nós intermediários
- Utilizar um termo *momentum*
- Adicionar ruído aos dados.

Para acelerar o processo de treinamento e evitar mínimos locais, a adição de um termo *momentum* Rumelhart et al. (1986) é uma das técnicas mais utilizadas. É muito utilizada por ser uma técnica simples e efetiva. A inclusão do termo *momentum* aumenta a velocidade de aprendizado (aceleração), reduzindo o perigo de instabilidade. Esse termo pode acelerar o treinamento em regiões muito planas da superfície de erro.

Outro problema que ocorre durante o treinamento de redes MLP é a possível ocorrência de *overfitting*. O *overfitting* ocorre quando, após um certo ciclo de treinamento, a rede, ao invés de melhorar, começa a piorar a sua taxa de acertos para padrões diferentes daqueles utilizados para o ajuste dos pesos. Diz-se então que a rede memorizou os padrões de treinamento, gravando suas peculiaridades e ruídos. Isto tem como resultados uma piora na capacidade de generalização da rede. Assim como para os problemas de lentidão e mínimos locais, existem alternativas para lidar com o problema de *overfitting*. As alternativas mais utilizadas para reduzir a ocorrência de *overfitting* são (Braga et al, 2000):

- Encerrar o treinamento mais cedo (quando o erro de validação começa a subir).
- Podar os pesos da rede.

Uma rede apresenta capacidade de generalização quando classifica corretamente padrões não utilizados no treinamento ou com ruído. A generalização ocorre através da detecção de

características relevantes do padrão de entrada. Assim, padrões desconhecidos são atribuídos a classes cujos padrões apresentam características semelhantes. A generalização também permite a tolerância de falhas.

2.5.6 AS REDES NEURAIAS EM ENGENHARIA CIVIL

Recentemente, o uso das redes neurais artificiais como aproximadores universais tem se popularizado em todas as áreas da engenharia e das ciências no geral. As aplicações em engenharia civil começaram a aparecer a partir dos últimos anos da década de 80. Atualmente, o campo de aplicação é muito amplo, abrangendo tópicos como otimização de processos, simulação de processos construtivos, previsão de ameaça sísmica, classificação de sinais provenientes de testes não destrutivos, estimativa de custos de construção, engenharia de transporte, análise estrutural, tratamento de águas, recuperação de aquíferos, previsão de vazões, avaliação do potencial de liquefação de solos e muitas outras.

São muitos os fatores que têm contribuído para estimular o interesse nas redes neurais; o mais notável é a sua capacidade de aprendizado e generalização a partir de exemplos, para produzir soluções confiáveis a problemas complexos ainda que a informação de entrada esteja contaminada com dados imprecisos ou incompletos.

Outros fatores que têm contribuído para aumentar o interesse nas RNAs têm a ver com o rápido desenvolvimento de computadores cada vez mais poderosos, com a capacidade necessária para manejar a grande carga computacional imposta pelos algoritmos de treinamento das RNAs (Networks et al., 1994).

Adeli (2001) apresenta de maneira detalhada os trabalhos sobre redes neurais em engenharia civil publicados entre 1989 e 2000. A maior parte dos trabalhos está compreendida na área da engenharia estrutural: previsão de cargas em vigas, definição de seções de vigas de concreto, seleção dos elementos estruturais de edificações, problemas de mecânica de fraturas, avaliação de danos em elementos estruturais, previsão do comportamento de conexões estruturais, previsão da resistência de elementos estruturais, determinação da relação carga-deslocamento em elementos estruturais, otimização dos processos de execução de projetos estruturais, identificação de sistemas dinâmicos estruturais, criação eficiente e automática de malhas de elementos finitos para análise estrutural, previsão das propriedades mecânicas e térmicas de materiais compostos, modelagem constitutiva de concreto e materiais compostos em geral.

2.5.7 AS REDES NEURAIAS EM GEOTECNIA

Em engenharia geotécnica, as aplicações mais comuns estão relacionadas com a caracterização e classificação de solos, fundações, recalques, escavações, estabilidade de taludes, reforço de solos, água subterrânea, dinâmica de solos e mineração (Shahin *et al.*, 2001).

A combinação de SIG com redes neurais tem sido utilizada por Pijanowski *et al.* (2002) para prever as mudanças do uso do solo numa região, baseado em um grupo de fatores relevantes.

Em estabilidade de taludes, encontram-se os trabalhos de Ni *et al.* (1996) e Neaupane & Achet (2004) nos quais são relacionados vários fatores predisponentes com os deslizamentos. Ambos os trabalhos incorporam o fator detonante chuva como dado de entrada no modelo neural. O objetivo dos trabalhos foi avaliar a estabilidade individual dos taludes. Não foi utilizada a ferramenta SIG nem encontrada a susceptibilidade numa região.

O trabalho de Martinez & Farias (2004) apresenta a utilização das RNA para modelar comportamentos tensão-deformação de materiais geotécnicos (no caso, as areias).

Garcia (2004) elabora uma avaliação quantitativa da susceptibilidade aos movimentos de massa para a cidade de Medellín (Colômbia) utilizando sistemas de informação geográfica. Para a medição da susceptibilidade, utiliza 9 fatores predisponentes: litologia, geomorfologia, uso do solo, distância a estruturas da rocha, distância a linhas de drenagem, curvatura das encostas, declividade, elevação (hipsometria) e mapa de inventário de deslizamentos. A informação foi dividida em planos de informação, um por cada fator predisponente. Ditos planos foram divididos também em classes que representam superfícies homogêneas do terreno. Para atribuir valores aos fatores predisponentes e às suas classes, utiliza a RNA para estimar os pesos mediante um processo de aprendizado. As RNAs adquirem o conhecimento por meio da apresentação sucessiva de dados de treinamento (grupo de fatores predisponentes e presença/ausência de movimentos de massa), ajustando os pesos dos diferentes nodos entre as iterações (épocas) até atingir um erro mínimo.

Yesilnacar & Topal (2005) elabora um mapa de suscetibilidade para a região de Hendek (Turquia) utilizando regressão logística e redes neurais, como resultados, o autor encontra que o modelo de redes neurais é mais realista que o modelo de regressão logística quando comparado com observações de campo.

Ermini *et al.*, (2005) fazem uso das RNA para produzir uma carta de susceptibilidade na região de Riomaggiore (Itália)

Chissolucombe (2009) utiliza RNA para a estimativa de deslocamentos e danos induzidos por escavações subterrâneas numa situação real ocorrida durante a escavação do Metrô de Brasília.

O trabalho de (Pradhan & Lee, 2009) apresenta cinco mapas de riscos, elaborado através da técnica de redes neurais, para diferentes regiões na Malásia, os autores obtiveram risco através do DEM, da distância a zona de ameaça, do mapa de cobertura do solo e da exposição dos objetos em risco. Em todos os casos, o modelo de rede neuronal apresenta uma precisão maior a 70%.

Pradhan & Lee (2010) utilizam o método de redes neurais para o mapeamento da suscetibilidade de deslizamento em Cameron (Malásia) usando a integração da declividade, aspecto topográfico, curvatura topográfica, distância a drenagem, litologia, tipos de solo, cobertura do solo, NDVI e parâmetros de precipitação associados em uma plataforma SIG. O autor concluiu, neste caso, que a declividade é o parâmetro mais importante no treinamento do modelo de rede neuronal, apresentando um peso de 0,205, seguido pela distância a drenagem com um peso de 0,141. O mapa de susceptibilidade elaborado apresenta uma precisão de 83% quando comparado com o mapa do inventário de movimentos de massa

Melo & Pedrollo (2015) e Pachepsky et al., (1996) utilizaram as RNA para estimar os parâmetros da curva de ajuste da curva característica solo-água. Em ambos os trabalhos, os autores mostram que é possível treinar uma RNA desde que se tenha uma base de dados abrangente.

3 MATERIAIS E MÉTODOS

No presente capítulo, discorre-se sobre os principais elementos concernentes ao arcabouço metodológico proposto para o uso de redes neurais artificiais para sistemas de alerta de escorregamentos superficiais deflagrados por chuvas em regiões montanhosas, concentrando-se, ainda, na explanação dos aspectos vinculados ao desenvolvimento e funcionamento da ferramenta computacional RNA aqui empregada.

3.1 ÁREA DE ESTUDO

A presente metodologia foi aplicada em uma área localizada no município de Barbosa, distante 36 km de Medellín (a capital do estado de Antioquia – Colômbia). O município está a uma altitude de 1300 msnm. A base de sua economia é a indústria, seguido pelo comercio e o setor agropecuário. A temperatura media anual é de 22°C; já a precipitação media anual é de 2003mm, com períodos chuvosos nos meses de maio e outubro. Segundo o ultimo censo a população é de 43.547 habitantes (DANE, 2006). O município possui uma área de 206 km²



Figura 3.1. Localização do município de Barbosa – Colômbia

3.2 ESTRUTURA METODOLÓGICA

O cerne da metodologia aqui aplicada apresenta-se como o estabelecimento de um procedimento capaz de calcular a ameaça de escorregamentos superficiais deflagrados por chuvas em uma área suburbana, baseando-se em informações relevantes do meio físico, devidamente estruturadas de forma espacial, as quais devem representar adequadamente a região em estudo, compatíveis com a escala de trabalho requerida.

Para isso, o trabalho foi dividido em cinco etapas, apresentadas na Figura 3.2 e descritas adiante:

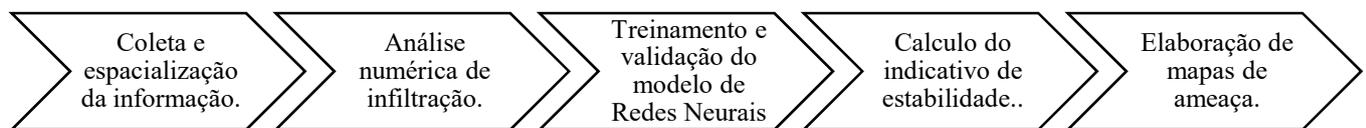


Figura 3.2. Metodologia da presente pesquisa.

3.3 ETAPA 1: COLETA E ESPACIALIZAÇÃO DA INFORMAÇÃO.

3.3.1 MAPA DE DECLIVIDADE

Os movimentos em massa são definidos como processos gravitacionais, razão pela qual a declividade é um fator importante para o estudo dos mesmos (Duncan, et al, 2014).

Foi elaborado, a partir do Modelo Numérico de Terreno (MNT) proveniente da topografia, o Modelo Digital de Elevação (MDE) de declividade com tamanho de pixel de 10m de lado. O mapa de declividade do local de estudo é apresentado na Figura 3.3

As declividades mais íngremes estão representadas pelas cores vermelha e laranja e as mais suaves são representadas pela cor verde. As declividades estão em uma faixa de 0% até 120%. Ainda que no mapa possa-se observar uma grande parte verde, a área de estudo é predominantemente íngreme.

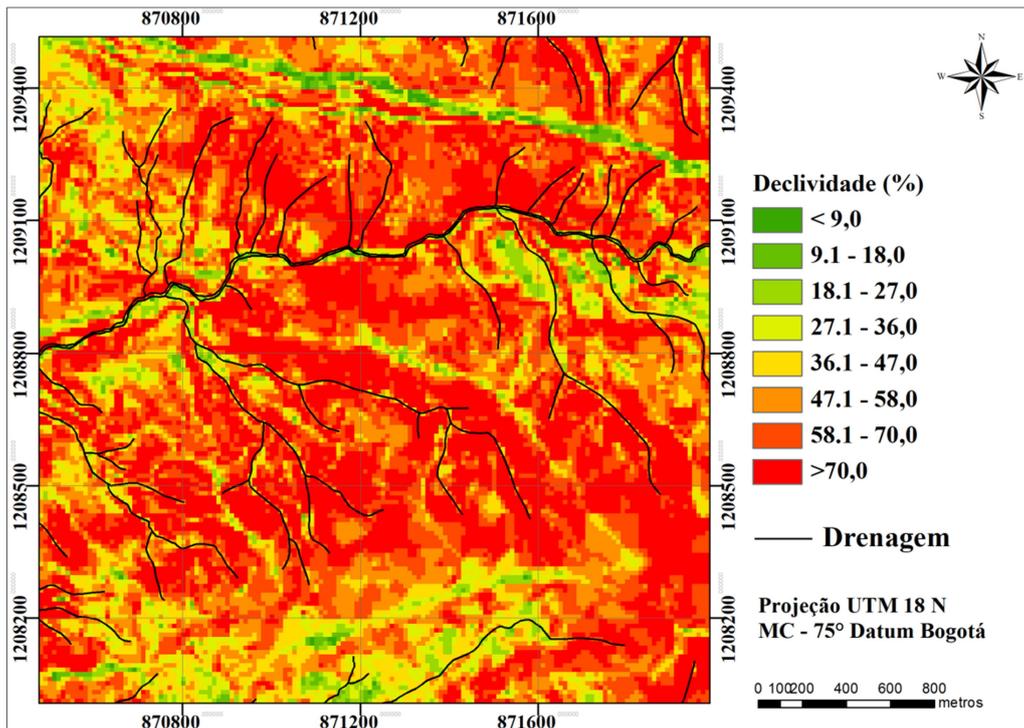


Figura 3.3. Mapa de declividade da área de estudo

No que tange à declividade, foi empregado o resultado da análise geomorfologia apresentado por Garcia (2006) que conclui que os movimentos de massa, para o Valle de Aburra, acontecem na sua maioria em declividades no intervalo entre 5° e 25° como apresentado na Tabela 3.1

Tabela 3.1. Porcentagem da área com respeito à área total de movimentos de massa (Garcia, 2006)

Declividade		Porcentagem da área com respeito à área total de movimentos de massa (%)
Graus	Porcentagem	
0 - 5	0 - 9	3,3
5 - 10	9 - 18	15
10 - 15	18 - 27	32,6
15 - 20	27 - 36	26,7
20 - 25	36 - 47	14,3
25 - 30	47 - 58	5,9
30 - 35	58 - 70	1,8
>35	>70	0,4

Assim sendo, a RNA a ser empregada nesta pesquisa será treinada com três declividades 10°, 20° e 30° intervalo este que representa aproximadamente 80% da área com

respeito à área total de movimentos de massa para o Valle de Aburra como proposto por Garcia (2006).

3.3.2 PROPRIEDADES DO SOLO

De acordo com a origem dos solos podem-se inferir algumas das suas propriedades, uma vez que o material parental é o responsável por suas principais características. Embora a escala geológica seja muito grande, ela permite fazer muitas simplificações, tais como uma unidade seja considerada homogênea nas suas propriedades, tanto hidrológicas quanto geotécnicas. A geologia da área é definida por dois tipos de solo, derivados da geologia, que foram definidos por AREA (2002) e é apresentada na Figura 3.4

3.3.3 UNIDADES GEOLOGICAS

Foi cedido por AREA (2018) a carta de geologia do município de Brabosa da qual foi possível extrair a geologia da área de estudo as diferentes associações que compõem a área de estudo, Figura 3.4

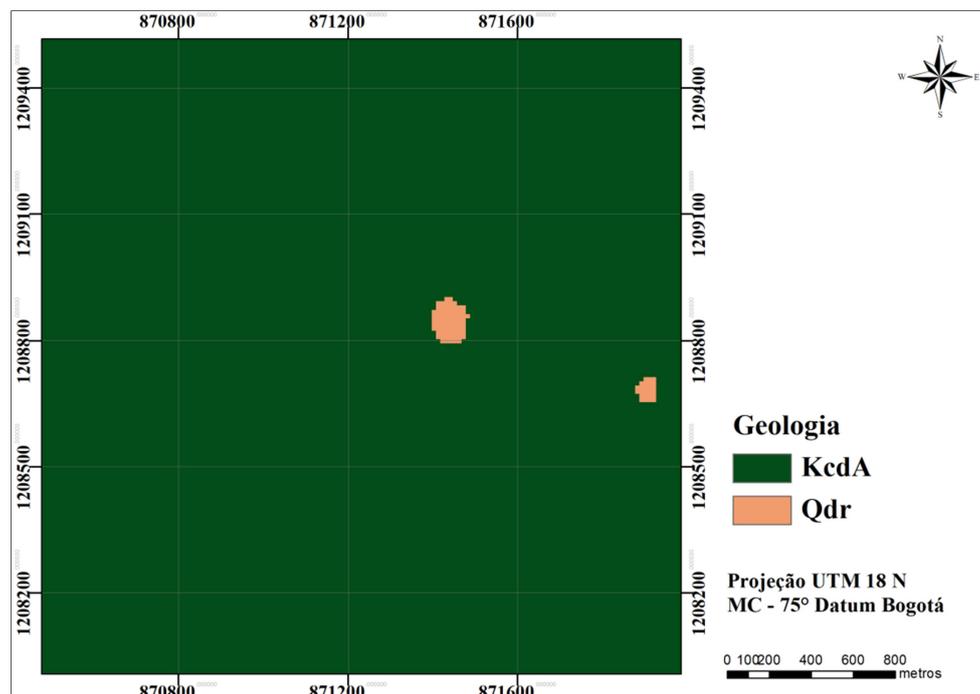


Figura 3.4. Geologia da área de estudo. (Modificado de AREA (2018))

- Batolito Antioqueno (KcdA): as rochas do Batolito correspondem a rochas do tipo granítico classificadas entre granodiorita e quartzodiorita, os minerais constituintes incluem

plagioclase, amphibole, biotite and quartz. It develops two types of horizons: a yellow and a red, both with argillaceous-silty texture.

- Depósitos de deslizamentos (Qdr): no município de Barbosa, aparecem depósitos de deslizamentos que estão relacionados a movimentos em massa, comuns no horizonte V do perfil de meteorização do Batolito Antioqueno.

Para efeitos do presente trabalho, os solos produto da geologia KcdA foram considerados como argilas-siltosas e os demais como areias-siltosas, conforme a descrição apresentada anteriormente.

3.3.4 PARÂMETROS GEOTÉCNICOS

Os parâmetros geotécnicos representam as propriedades do solo que efetivamente governam seu comportamento e resistência. Esses parâmetros não são constantes no espaço e dependem de muitos fatores como a origem da sua formação, dos níveis de tensões aos quais está submetido, dentre outros.

- **Coesão (c).** De acordo com estudos prévios elaborados por AREA (2001), a coesão efetiva na formação KcdA está entre 9 kPa e 17 kPa, e na formação Qdr entre 8 e 12kPa.
- **Ângulo de Atrito (ϕ).** Os ângulos de atrito efetivo para solos argilos-siltosos da área de estudo estão na faixa de 16° até 24° de acordo com os resultados dos ensaios realizados por AREA (2002) e entre 18° e 26° para as areias-siltosas
- **Peso específico do Solo Saturado (γ).** As faixas apresentadas por AREA (2002), estão entre 18,00 kN/m³ e 18,8 kN/m³, os pesos unitários secos estão entre 14,3 e 14,9 kN/m³.

O presente trabalho considera variáveis independentes com natureza aleatória, a coesão efetiva e o ângulo de atrito efetivo do solo, com o qual foi possível obter cartas com a espacialização para cada um desses parâmetros. Foram obtidas então, grades aleatórias de valores com distribuição normal e tamanho de pixel 10m de lado.

As distribuições estatísticas normais para as variáveis estatísticas foram definidas a partir dos valores médios e dos seus desvios padrões, sendo estes últimos determinados pela Equação 3.1:

$$\sigma_i = \bar{X}_i \cdot \frac{CV_i}{100} \quad (3.1)$$

Onde σ_i corresponde ao desvio padrão das variáveis estatísticas, \bar{X}_i refere-se à média da variável em análise e CV_i é o coeficiente de variação expresso em porcentagem. Os coeficientes de variação considerados em relação à coesão efetiva e ao ângulo de atrito efetivo referem-se, respectivamente, aos valores de 20% e 10% (Assis et al. 2012) conforme resumo apresentados na Tabela 3.2

Tabela 3.2. Parâmetros geotécnicos empregados.

	Media		Coeficiente de Variação	Desvio Padrão	
	Areia	Argila		Areia	Argila
c' (kPa)	10	14	20%	2	2,8
ϕ' (°)	22	18	10%	2,2	1,8
γ (kN/m ³)	18	17	-	18	17

Assis et al. (2012) propõe usar para o peso específico um coeficiente de variação menor a 8% valor que estatisticamente contribui em 0,1% na variância final quando empregada uma equação de talude infinito. Assim então se justifica que as variáveis independentes com natureza aleatória sejam unicamente a coesão efetiva e o ângulo de atrito efetivo do solo.

3.3.5 ESPESSURA DO SOLO INTEMPERIZADO.

A avaliação da espessura da camada de solo torna-se essencial diante da análise de temas que envolvem processos hidrológicos desenvolvidos em encostas, assim como na própria estabilidade de taludes (Tromp-Van Meerveld & McDonnell, 2006; Lanniet al., 2012).

Diversos fenômenos hidrogeomorfológicos, tais como os escorregamentos, fluxos de detritos e inundações, dependem diretamente da distribuição espacial da profundidade do solo. Justamente por isso, a profundidade do solo é uma variável de extrema importância em estudos ambientais, tais como a modelagem hidrológica, geomorfológica ou de estabilidade de encostas. Atualmente, as metodologias para definir a distribuição espacial deste parâmetro nas encostas são escassas. As metodologias existentes para estimativa da profundidade do solo podem ser divididas em: (i) métodos de campo e (ii) matemáticos. Os métodos de campo são capazes de realizar esta tarefa de maneira pontual ou em áreas de reduzidas dimensões, além de demandarem grande tempo e esforço. Os métodos matemáticos têm a capacidade de

definir uma distribuição espacial para a profundidade do solo sobre grandes áreas, porém, na maioria das vezes, as metodologias são aplicáveis apenas para casos específicos e restritos (Michel, 2015).

Duas abordagens, propostas por Hjerdt (2004), frequentemente utilizadas em avaliações regionais de grande escala, tem como base a relação prevista entre profundidade do solo com registros de altimetria e declividade. Estes dois modelos são empregados em variados casos no intuito de estimar a distribuição espacial da profundidade do solo em casos em que uma rápida e fácil abordagem é requerida, como em modelagens em nível de escala de bacias, apesar de dependerem de simplificações de caráter geomorfológico.

Usando como base as abordagens anteriormente mencionadas, propõe-se um procedimento para o cálculo aproximado da camada de solo em regiões montanhosas usando relações geomorfológicas aprimoradas do terreno. Tais características referem-se a fatores definidos pela distância de um dado ponto às drenagens e da distribuição das declividades (Eduardo Montoya Botero, Azevedo, et al., 2015).

Este método tem por finalidade fornecer uma ferramenta capaz de estabelecer de maneira rápida uma previsão deste insumo para fins de análise de estabilidade regional de encostas em ambientes tropicais montanhosos. Em variados modelos de análise que avaliam as condições de segurança dos taludes, quer em termos de susceptibilidade, quer de perigo de deslizamentos, a espessura do material não consolidado apresenta-se como um dado de entrada requisitado por estes elementos. A proposta se baseia no comportamento da distribuição do solo frente às inclinações do terreno. Considera-se que quanto mais plana uma dada região, maior será a ação da deposição de sedimentos, corroborando para um maior acúmulo de material nestas áreas. Em contrapartida, à medida que o ângulo da vertente aumenta, menor será a taxa de acumulação e, conseqüentemente, a profundidade do solo será menor, tendendo ao afloramento da rocha (Eduardo Montoya Botero, AZEVEDO, et al., 2015). Estas condições se refletem na Equação 3.2.

$$Z_s = (Z_{s_{\max}} - Z_{s_{\min}}) \cdot \left(1 - \frac{1}{\tan(\theta_{\text{lim}})} \tan \theta\right) + Z_{s_{\min}} \quad (3.2)$$

Onde:

Z_s = espessura do solo decorrente da influência da declividade, em metros;

$Z_{s_{\max}}$ = espessura máxima prevista na área de estudo, em metros;

$Z_{s_{\min}}$ = espessura mínima observada na área de estudo, em metros;

θ = valor da declividade em uma dada célula, em graus;

θ_{lim} = valor de declividade estipulado como limite de influência para a alteração da camada de solo.

O valor θ_{lim} acima mencionado define a inclinação a partir da qual a atuação deste fator não irá mais interferir na variação da espessura do solo. Isto representa que valores de declividade iguais ou superiores ao patamar estabelecido irão proporcionar a profundidade mínima fixada. Este limite corresponde a uma informação que deverá ser conseguida por meio da observação, em campo, de locais onde se constata a constância da camada de solo.

A Figura 3.5 representa as configurações geradas da Equação 3.2 pelo uso de distintos valores estipulados como limite de declividade.

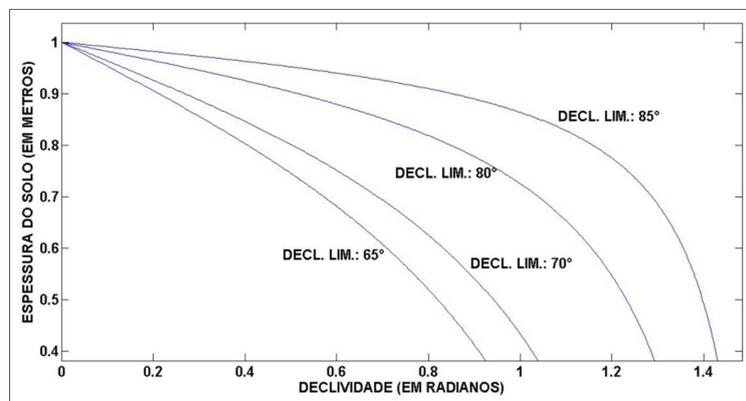


Figura 3.5. Curvas de estimativa de profundidade para valores limites de declividade distintos.

A figura 3.5 aparece de forma ilustrativa para aclarar o efeito da variável θ_{lim} , nesta representação, a espessura considerada variou hipoteticamente de zero a um (valores que devem ser confirmados em campo). Quatro valores limites para a inclinação foram utilizados na plotagem das funções: 65°, 70°, 80° e 85°. O que se observa neste gráfico é que a lei de variação da profundidade do perfil de solo, da forma como foi definida, estabelece que quanto maior o valor de θ_{lim} fixado, maior será a medida prevista pelo método, para um mesmo valor de inclinação de talude.

A transição entre as medidas máxima e mínima pré-estabelecidas de profundidade é processada de forma mais suave para as curvas que consideram um patamar mais baixo no que tange ao limite de inclinação das vertentes que não influencia na definição do perfil pedológico da região em estudo.

Agrega-se a esta hipótese, a consideração da interferência da distância das vertentes na definição da capa de solo, que segundo Pradhan & Lee (2010), é o segundo parâmetro mais

importante para o treinamento de um modelo de rede neuronal para o cálculo de susceptibilidade. Esta característica é adicionada ao modelo segundo a Equação 3.2

$$Z_{s_{\text{dist}}} = Z_{s_{\text{max}}} \cdot \tanh(a \cdot x) \quad (3.2)$$

Onde:

$Z_{s_{\text{dist}}}$ = espessura do solo decorrente da influência da distância horizontal das vertentes, em metros;

$Z_{s_{\text{max}}}$ = espessura máxima prevista na área de estudo, em metros;

a = parâmetro que controla a curvatura;

x = distância horizontal do ponto considerado a drenagem mais próxima.

O termo \tanh corresponde ao cálculo da tangente hiperbólica do produto ax . Esta interação atua de forma que quanto maior o afastamento horizontal de determinado ponto à drenagem mais próxima, maior será a tendência de crescimento da camada de solo.

A integração dos dois aspectos explicitados anteriormente constitui o modelo proposto para a espessura final seguindo a Equação 4.3.

$$Z_s = (Z_{s_{\text{max}}} - Z_{s_{\text{min}}}) \cdot \left\{ \left[1 - \frac{1}{\tan \theta_{\text{lim}}} \cdot \tan \theta \right] \cdot [\tanh(a \cdot x)] \right\} + Z_{s_{\text{min}}} \quad (3.3)$$

Na Equação 3.3, Z_s é a espessura prevista total e os demais termos já foram apresentados anteriormente. A RNA será treinada com três espessores de solo intemperizado, a saber, 1,0m, 2,0m e 3,0m já que, segundo Montrasio (2008) escorregamentos superficiais acontecem em profundidades de 0,5m - 3,0m.

3.3.6 CURVA CARACTERÍSTICA SOLO-ÁGUA

O fluxo de água e ar são dois fenômenos fortemente acoplados. Mudanças tanto nas pressões de água quanto nas pressões de ar causam alterações na quantidade de água armazenada no solo. O acoplamento entre o fluxo de água e ar no solo é obtido exprimindo a curva característica solo-água em termos de sucção matricial.

O valor da sucção em um solo está diretamente relacionado com a quantidade de água presente nos seus vazios. Quanto menos o volume de água presente, maior será o valor da sucção, e vice-versa. A partir de valores de sucção com os seus correspondentes valores de saturação ou umidade volumétrica da massa de solo, plota-se uma curva chamada curva

característica solo água. Está é uma relação constitutiva importante para descrever o fluxo em solos não saturados e é definida como a relação entre o conteúdo de água e a sucção no solo (Fredlund & Xing, 1994). O conteúdo de água pode ser expresso em termos de umidade volumétrica (θ), umidade gravimétrica (w) ou saturação (S), e a sucção em termos de sucção matricial ($u_a - u_w$) ou sucção total (ψ). Para valores altos de sucção, a sucção matricial e a total podem, geralmente, ser assumidas como equivalentes (Fredlund & Xing, 1994)

A curva característica pode ser representada através de diversos tipos de equações de ajuste. Essas equações são ajustadas a dados obtidos experimentalmente, obtendo-se uma representação matemática da curva característica solo-água que pode ser usada em análises numéricas e na previsão de diversas propriedades de solos não saturados. Os parâmetros de ajuste dessas curvas apresentam coeficientes de variação superiores a 100% (Wang et al. 2015)

Cavalcante & Zornberg (2017) sugerem uma relação para representar a curva de retenção solo-água. Os autores adotam uma relação logarítmica entre a sucção e o conteúdo volumétrico de água [$\psi(\theta)$] e uma relação linear entre a condutividade hidráulica e o conteúdo volumétrico de água [$k_z(\theta)$] apresentados nas Equações 3.3 e 3.4 respectivamente

$$\psi(\theta) = \frac{1}{\delta} \ln \left(\frac{\theta - \theta_r}{\theta_s - \theta_r} \right) \quad (3.3)$$

Onde:

θ_s é o conteúdo volumétrico de água na saturação (L^3/L^3)

θ_r é o conteúdo volumétrico de água residual (L^3/L^3)

δ parâmetro hidráulico de ajuste ($M^{-1}LT^2$)

$$k_z(\theta) = k_s \left(\frac{\theta - \theta_r}{\theta_s - \theta_r} \right) \quad (3.4)$$

Onde

k_s é a condutividade hidráulica saturada do solo (L/T)

Em relação à curva característica, a RNA será treinada afim de que a mesma consiga reconhecer dois tipos de solos, areia-siltosa e areia-siltosa, solos estes representativos da área de estudo.

3.3.7 CHUVA

Os movimentos em massa são fenômenos naturais que ocorrem devido a mudanças nas propriedades físicas dos materiais que conformam uma vertente. Mas existem fatores externos – como a chuva – capazes de gerar de maneira lenta ou rápida a ocorrência desses processos (G. Wang & Sassa, 2007)

Terlien (1998) afirma que em países tropicais, o número de dias de chuva antecedente que influencia na geração de movimentos de massas varia em função da profundidade da superfície de ruptura, de maneira que a chuva diária e intensa detona movimentos em massa superficiais menores de 2,0m de espessura, enquanto que chuva antecedente de vários dias detona movimentos em massa relativamente profundos de mais de 6,0m de espessura. A análise estatística das intensidades máximas permite obter curvas que indicam quais são as intensidades máximas associadas a diferentes períodos de retorno e durações dos eventos de precipitação. Essas curvas são chamadas de Intensidade – Duração – Frequência (IDF). A entrada meteorológica no modelo de rede neural está representada pela chuva, a qual foi obtida utilizando as curvas propostas por Gomez (2002). A RNA deve ser treinada com uma combinação abrangente de intensidade e durações, pelo qual, das curvas IDF apresentadas por Gomez (2002) foram selecionadas cinco chuvas, apresentadas na Figura 3.6

As chuvas escolhidas seguem a premissa de Melo & Pedrollo (2015) e Pachepsky et al., (1996) quem sugerem que é possível treinar uma RNA desde que se tenha uma base de dados abrangente, ou seja, uma base de dados onde todos os casos valores possíveis das variáveis são apresentados para o modelo de RNA no processo de treinamento e como pode ser visto na Figura 3.6 essas chuvas abrangem toda a curva IDF começando com duas chuvas de baixa duração e alta intensidade, duas chuvas de baixa intensidade e alta duração e uma chuva intermediária.

A vantagem de utilizar as curvas IDF é que elas podem ser associadas a uma probabilidade de ocorrência de escorregamentos, uma vez que são o produto de uma análise estatística de valores máximos, além de poderem ser associadas ao período de vida útil das construções civis.

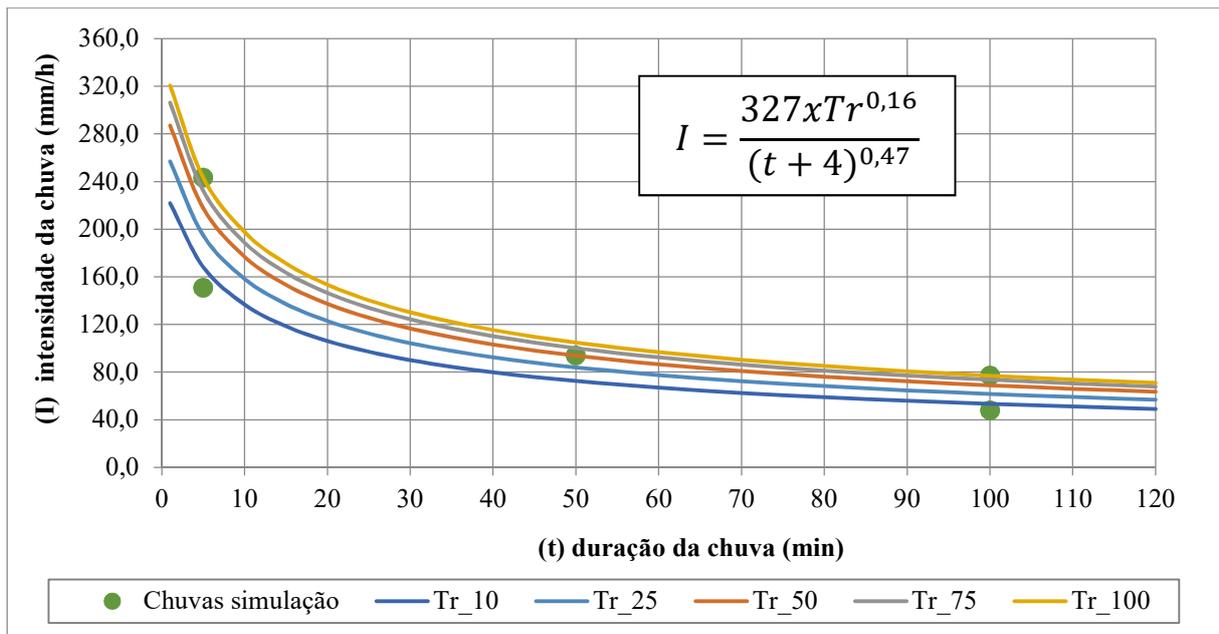


Figura 3.6. Curva Intensidade - Duração - Frequência. Gomez (2002)

A análise de fluxo em solos não saturados é fundamental para o entendimento de mecanismos de infiltração em encostas. O processo de infiltração pode ser compreendido e modelado utilizando os conceitos de mecânica do contínuo e as propriedades de solos não saturados, que estabelecem suas características de armazenamento e de percolação de água. Além do fluxo de água, outro mecanismo de fluxo relevante é o fluxo de ar. O ar e a água do solo possuem características tanto de imiscibilidade quanto de miscibilidade. A água pode ser encontrada no ar do poro do solo na forma de vapor. Ao mesmo tempo, a grande parcela de água, que ocupa os vazios do solo, compete por espaço com o ar livre. As pressões relativas de ambas as fases acabam por interferir no fluxo e no volume armazenado. (Camapum de Carvalho, 2012).

A modelagem do fluxo em solos não saturados se baseia em hipóteses fundamentais adotadas no desenvolvimento teórico, no estabelecimento de variáveis de estado adequadas e na adoção de leis fundamentais de conservação de massa.

3.3.8 CHUVA ANTECEDENTE

Rahardjo et al.(2001), constataram que tanto a chuva deflagradora como a chuva antecedente constituem importantes fatores detonadores de deslizamentos. Por outro lado indicam que a chuva deflagradora ou a chuva antecedente isoladamente não podem ser usados como um determinante para deslizamentos já que quando se acrescenta a chuva antecedente

se incrementa também a permeabilidade do solo e subseqüentes chuvas podem deflagrar um deslizamento.

No Valle de Aburra, o maior condicionante para a ocorrência de movimentos em massa é a chuva antecedente maior a 60 mm para 30 dias, 160mm para 60 dias e 200mm para 90 dias (Aristizábal et al., 2011).

No presente trabalho foi considerada a chuva antecedente como uma variação na posição do lençol freático, Ocampo-Araya, M.D.C. (2016) fez um comparativo de movimentos de massa e verifica que os movimentos de massa acontecem para relações de espessura de solo (Z_s) dividido pela altura do lençol freático (Z_w) variando de 30% a 70%. Essa comparação foi obtida mediante análises de escorregamentos históricos na Guatemala, Mexico, Perú e Brasil.

3.4 ETAPA 2: ANALISE NUMERICA DE INFILTRAÇÃO

A análise de fluxo em solos não saturados é fundamental para o entendimento de mecanismos de infiltração em encostas. O processo de infiltração pode ser compreendido e modelado utilizando os conceitos de mecânica do contínuo e as propriedades de solos não saturados, que estabelecem suas características de armazenamento e de percolação de água. Além do fluxo de água, outro mecanismo de fluxo relevante é o fluxo de ar. O ar e a água do solo possuem características tanto de imiscibilidade quanto de miscibilidade. A água pode ser encontrada no ar do poro do solo na forma de vapor. Ao mesmo tempo, a grande parcela de água, que ocupa os vazios do solo, compete por espaço com o ar livre. As pressões relativas de ambas as fases acabam por interferir no fluxo e no volume armazenado (Camapum de Carvalho et al., 2012).

A finalidade dessas análises numéricas é obter o perfil de poropressão depois de findada cada uma das chuvas em cada uma das encostas analisadas, representadas pela declividade. Para tal fim, foi utilizado o modulo SEEP-W do software GEOSLOPE.

3.5 ETAPA 4: TREINAMENTO E VALIDAÇÃO DO MODELO DE RNA

Antes de chegar neste ponto da pesquisa, um modelo de RNA foi treinado e verificado para uma zona conhecida como Pajarito na Cidade de Medellín (Colômbia) com o objetivo de avaliar a viabilidade da aplicação das RNAs para previsão de escorregamentos superficiais deflagrados por chuva em encostas naturais e verificar o funcionamento de quatro arquiteturas

de RNA diferentes (Montoya, 2013). Essas quatro redes do tipo Multi Layer Perceptron, com uma arquitetura arranjada por duas camadas intermediárias de cinco, dez, quatro e três neurônios, respectivamente, uma camada de entrada com três neurônios e uma camada de saída com um neurônio. Segundo Falaschi et al (2009) são as melhores e as mais usadas para a modelagem de problemas de grande escala.

As quatro redes foram treinadas usando o algoritmo Levenberg-Marquardt, implementado no programa Matlab, cujo desempenho, em termos de erro quadrático mínimo, mostrou-se melhor que outros algoritmos, como o gradiente descendente simples. O conjunto de dados para o treinamento dessas quatro redes previamente treinadas foi constituído por uma base de dados elaborada artificialmente (Eduardo M. Botero et al., 2016), assim:

A área de estudo, de 1,5 km², foi dividida em pixels quadrados de 10m de lado, foi produzido o mapa de declividade e classificado usando um histograma de frequências com nove classes, como sugeridas por Garcia (2004). Desse histograma aparecem nove declividades (16, 25, 29, 32, 36, 47, 58, 70 e 100%) que serão consideradas como a primeira entrada no modelo de RNA.

A geologia da encosta Pajarito é constituída por rochas metamórficas que apresentam solos residuais silto-argilosos de espessura de solo de 30 m. O autor utilizou valores médios para os parâmetros de coesão e ângulo de atrito e uma única curva característica solo-agua.

Posteriormente, usando a curva IDF da estação San Cristóbal, pertencente à EPM e localizada dentro de Pajarito, foram tomadas as vinte intensidades (I) correspondentes a combinações dos períodos de retorno (Tr) de 2.33, 10, 50 e 100 anos, com as durações (D) de 20, 40, 60, 80 e 100 minutos.

De posse dessas nove declividades e vinte chuvas “características” foram realizadas 180 simulações numéricas de infiltração, sendo cada simulação a combinação de uma das vinte intensidades com uma das nove declividades. As simulações foram realizadas no código de elementos finitos preparado por Garcia (2010) com a finalidade de encontrar o valor da poropressão, num perfil vertical localizado na metade de cada encosta (ver Figura 5.6), a fim de se fazer logo a relação de forças atuantes e resistentes e obter um fator de segurança ao finalizar cada chuva. Assim, a entrada em cada RNA é declividade do pixel, a duração da chuva e o perdido de recorrência e a saída o fator de segurança na encosta com essas condições geométrica e hidráulicas.

Essas RNA treinadas para a área de Pajarito servem para demonstrar que a definição da arquitetura ótima para um problema específico de aproximação não é uma questão trivial, obrigando o usuário a testar sistematicamente diferentes arquiteturas até conseguir uma que

apresente as melhores características em termos de tempo de aprendizagem, facilidade de implementação, capacidade de generalização e maior correlação das saídas com os valores calculados mediante a estabilidade de taludes nas etapas de treinamento, validação e verificação da mesma. A melhor arquitetura, em termos de precisão (90%) quando comparada com a base artificial descrita, foi uma RNA constituída por duas camadas intermediárias de quatro neurônios cada. O treinamento e validação da RNA foram executados no programa Matlab, que possui um módulo específico de RNA.

Uma base de dados para o treinamento da RNA não terá de conter todas as combinações de chuva, declividade e parâmetros do solo, mas deverá incluir um número suficiente delas, para que a RNA possa aprender, mas não memorizar. Assim, a RNA seria capaz de usar sua capacidade de generalização para produzir respostas aceitáveis quando for consultada com dados não incluídos no conjunto de dados de treinamento. (Ghaboussi, 1992).

Essa arquitetura que apresentou precisão de 90% na região de Pajarito será a arquitetura a ser considerada para o treinamento da RNA a ser empregada em Barbosa. Serão tomados como valores de entrada a declividade, a chuva caracterizada por uma duração e intensidade, parâmetros que permitam identificar o tipo de solo, espessura da camada potencial de solo a ser deslizada, sendo as saídas a poropressão ao finalizar uma determinada chuva para cada pixel nessas condições.

A validação da RNA será feita usando-se um novo banco de dados a ser elaborado utilizando elementos característicos da área de estudo em Barbosa.

3.6 ETAPA 4: CÁLCULO DO INDICATIVO DE ESTABILIDADE

3.6.1 FATOR DE SEGURANÇA

Com as análises numéricas de infiltração, anteriormente descritas, tem-se o valor da poropressão em cada um dos perfis ao finalizar cada uma das precipitações em estudo.

Além disso, têm-se parâmetros geométricos e, adicionando os parâmetros de resistência, é possível fazer uma relação entre as forças atuantes e as forças resistentes em todos os diferentes cenários de combinação de declividade com chuva, o que resulta num valor de fator de segurança.

A Figura 5.6 esquematiza o diagrama de corpo livre que será utilizado para obter o fator de segurança.

A água que entra na encosta é dirigida paralelamente à superfície por uma camada impermeável a certa profundidade. A altura piezométrica da água está na superfície inclinada

do solo, as linhas de fluxo são paralelas à declividade, e as linhas equipotenciais são perpendiculares à declividade. A pressão da água é, por conseguinte, zero na superfície do solo e aumenta com a profundidade, tal como indicado na Figura 3.7

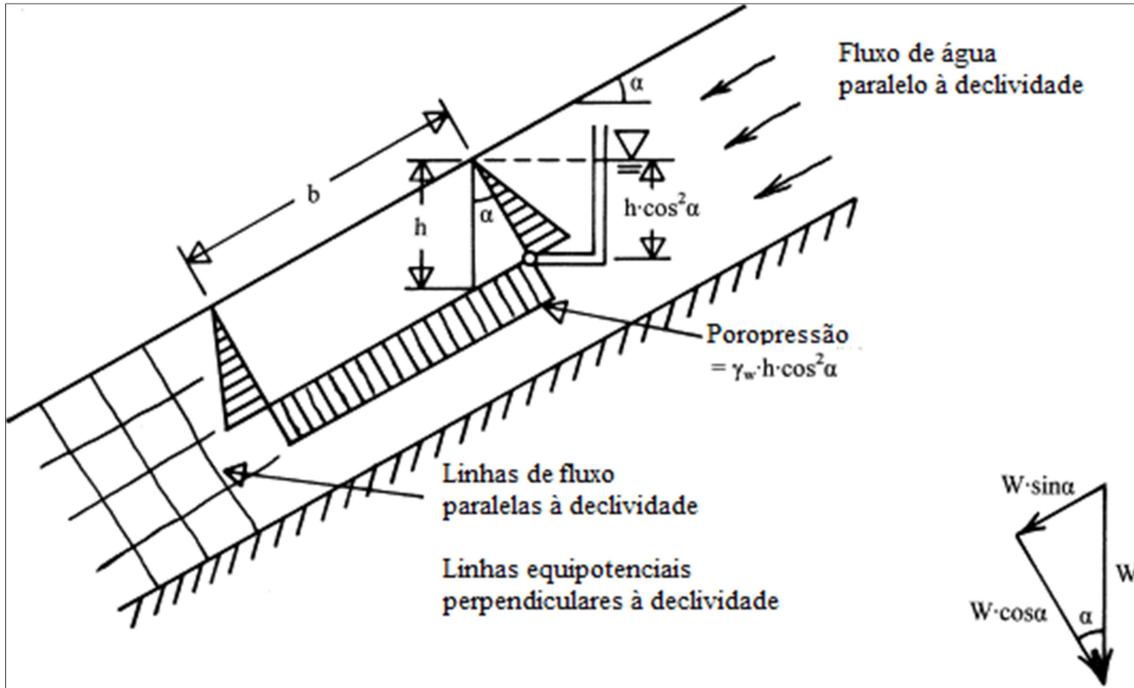


Figura 3.7. Diagrama de corpo livre talude infinito. (Modificado Lade, (2010)).

Na profundidade vertical h , a pressão da água é calculada seguindo a Equação 3.6

$$u = \gamma_w h (\cos \alpha)^2 \quad (3.6)$$

O peso total do bloco, com profundidade $h \cos \alpha$ e longitude b são calculados com a Equação 3.7

$$W = \gamma_{sat} b h \cos \alpha \quad (3.7)$$

onde γ_{sat} é o peso específico saturado do solo. As forças laterais paralelas à encosta, nas duas extremidades do corpo livre, são opostas e iguais em grandeza num talude infinito, de tal forma que quando se faz o equilíbrio elas se anulam.

Assim, apenas a força vertical W e a pressão da água u dirigidos perpendicularmente à base são considerados no equilíbrio de forças do bloco. A força vertical W é decomposta em duas componentes: uma paralela e outra perpendicular à declividade, como mostrado na

Figura 3.7 Esses componentes são então empregados na determinação da tensão cisalhante " τ ", Equação 3.8, e da tensão normal efetiva " σ' " Equação 3.9, na base do bloco.

$$\tau = \frac{W \sin \alpha}{b} = \gamma_{sat} h \cos \alpha \sin \alpha \quad (3.8)$$

$$\sigma' = \frac{W \cos \alpha}{b} - u(\cos \alpha)^2 = \gamma_{sat} h(\cos \alpha)^2 - u \quad (3.9)$$

Como indicativo de estabilidade foi utilizada a Equação 3.10 de fator de segurança de talude infinito:

$$FS = \frac{\sigma'}{\tau} = \frac{C' + [\gamma h (\cos \alpha)^2 - u] \tan \varphi'}{\gamma h \cos \alpha \sin \alpha} \quad (3.10)$$

Onde C' refere-se à coesão efetiva (em kPa), γ relaciona-se ao peso específico do solo (na unidade de kN/m³), h é a profundidade do solo na superfície de ruptura potencial, α mostra-se como a inclinação do talude (em graus), u é a poropressão (em kPa) e φ' representa o valor do ângulo de atrito efetivo do solo (em graus). Foi escolhida esta equação pelo fato da facilidade e rapidez no cálculo das forças estabilizadoras e desestabilizadoras, além das variáveis serem de fácil coleta.

Cabe ressaltar que é possível empregar outras equações de fator de segurança, diferentes de la anteriormente apresentada, como as propostas por Chae et al., (2015); Cavalcante & Camapum de Carvalho (2017); Rojas, K.R.C. (2017), uma vez que o objetivo é calcular um indicador de estabilidade para as encostas da área em estudo e com base nesse resultado fornecer ferramentas na toma de decisões.

3.7 ETAPA 5: ELABORAÇÃO DE MAPAS DE AMEAÇA

Aproveitando que a RNA a ser treinada, validada e verificada conseguirá calcular a poropressão para cada pixel sob condições previamente determinadas de chuva e parâmetros do solo, será possível verificar quais combinações de Intensidade (I) e Duração (D) conseguem produzir $FS < 1$, como apresentado na Figura 3.8

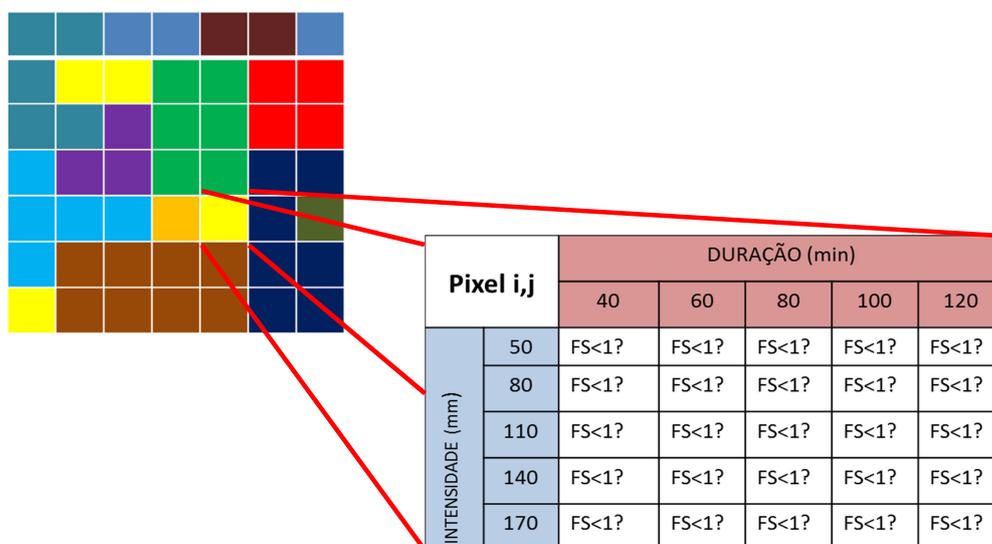


Figura 3.8. Metodologia para elaboração de mapas de ameaça

Desta forma, será possível identificar, para um determinado pixel, quais são as combinações de I, D que geram $FS < 1$, e juntando as matrizes de todos os pixels obtém-se a partir de quais valores de I e D deve-se gerar uma alerta na zona.

Por fim, segue na Figura 3.9 a árvore de decisões da metodologia explanada, desde a organização dos dados de entrada até a confecção do produto final que, para este caso, são os mapas de ameaça para umas condições impostas pelo usuário.

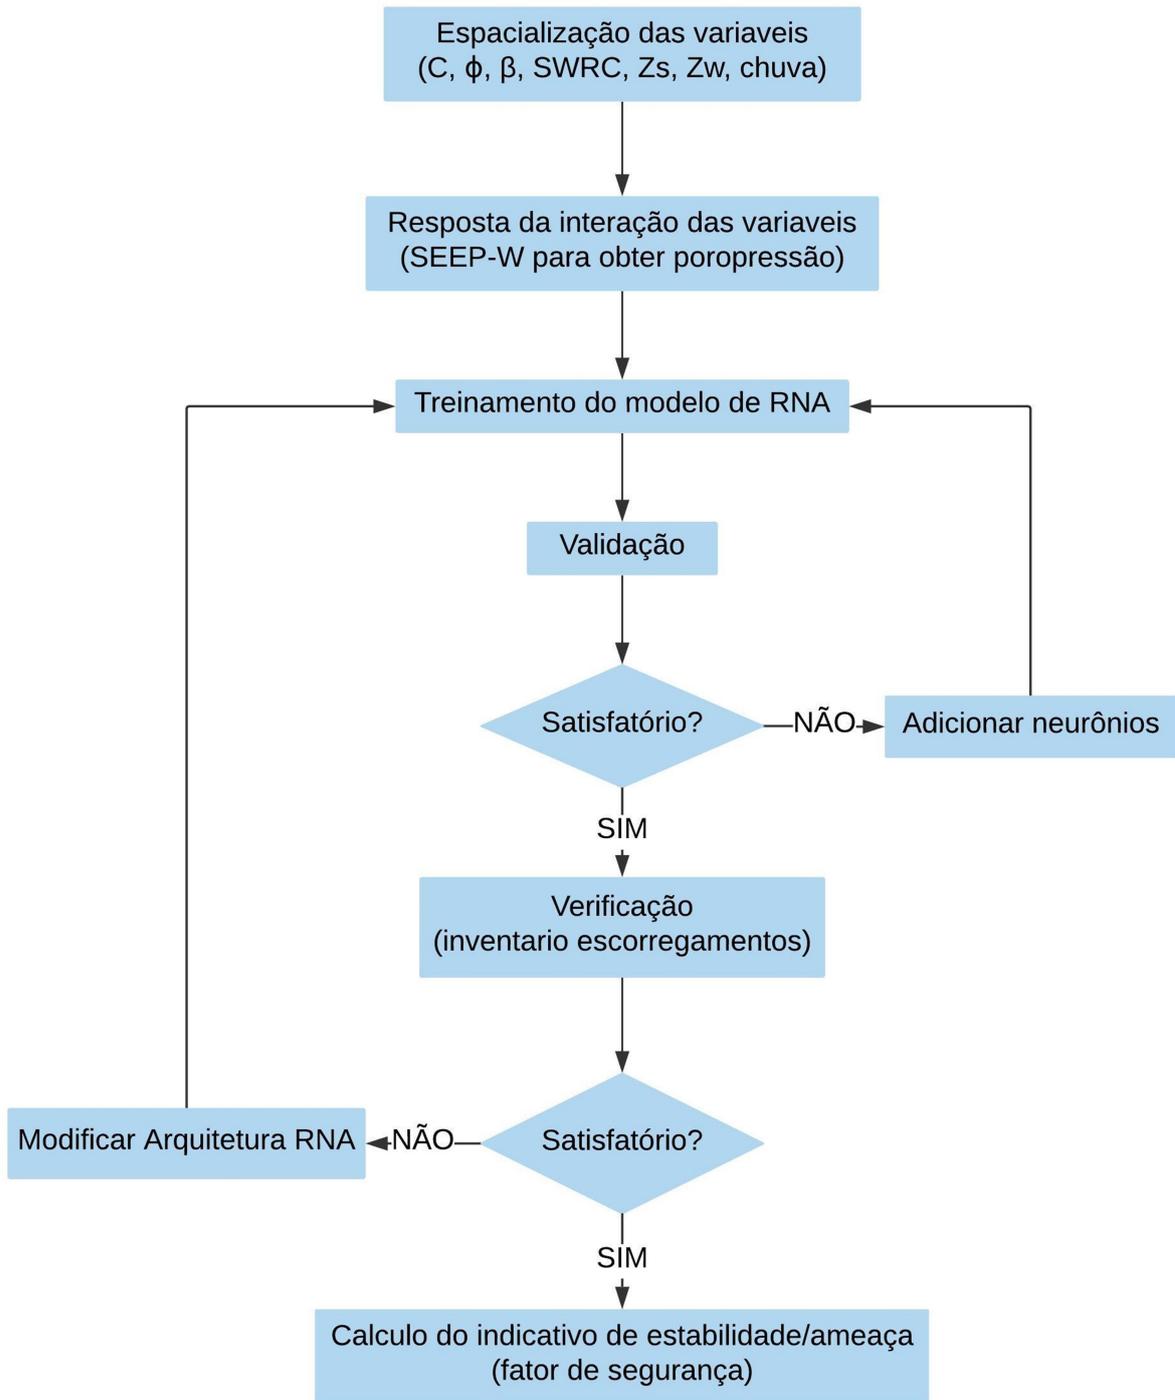


Figura 3.9. Árvore de decisões

4 RESULTADOS

Segue, na Figura 4.1, o fluxograma que apresenta a sequencia da aplicação desta proposta metodológica para aplicação de RNA para sistemas de alerta de escorregamentos superficiais deflagrados por chuvas, iniciando com a entrada de parâmetros até o calculo da ameaça e os resultados obtidos ao aplicar dita metodologia em uma área de estudo no município de Barbosa.

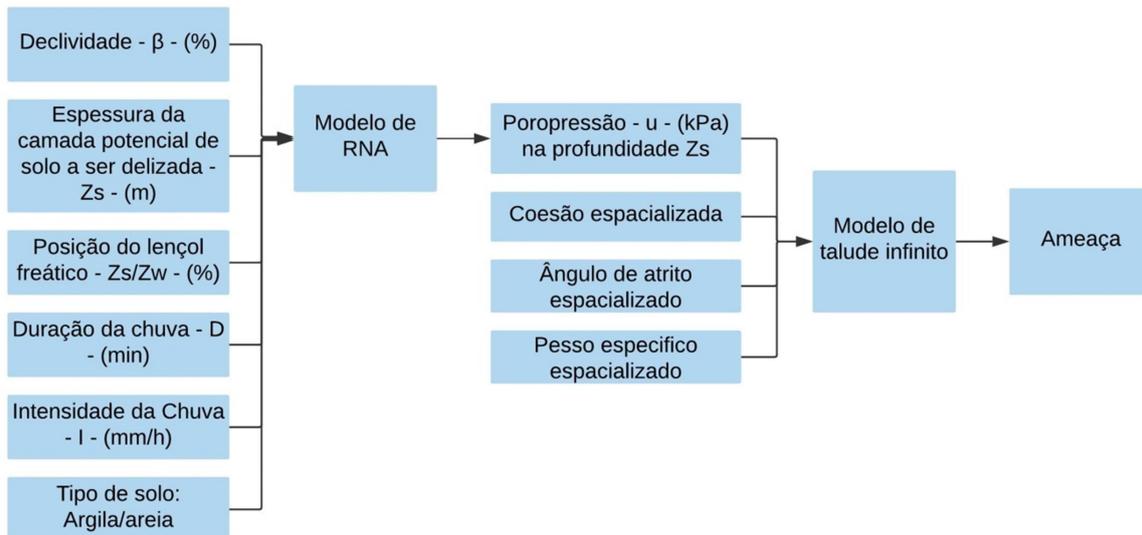


Figura 4.1. Sequencia calculo de ameaça.

4.1 ESPESSURA DO SOLO

A escolha da inclinação limite neste trabalho se deu após efetuar a análise de estatística descritiva sobre o plano de informação desta variável. Observa-se que a média está situada em 26° , enquanto que o desvio padrão é igual a 12° . Desta forma, optou-se por considerar um valor crítico (θ_{lim}) para a declividade de 38° , ligeiramente acima da medida que compreende a média acrescentada de dois desvios padrões. O valor da variável a foi fixado em 0,04, enquanto as espessuras máximas e mínimas previstas correspondem aos valores 3 m e 1 m, para profundidade potencial de deslizamentos deflagrados por chuvas.

Por meio da organização dos dados espaciais da região de estudo na plataforma ARCGIS, foram conseguidas as grades numéricas resultantes com pixel de 10m de lado, as quais sujeitas ao processo de fatiamento culminaram na carta temática para espessura do solo, apresentado na Figura 4.2

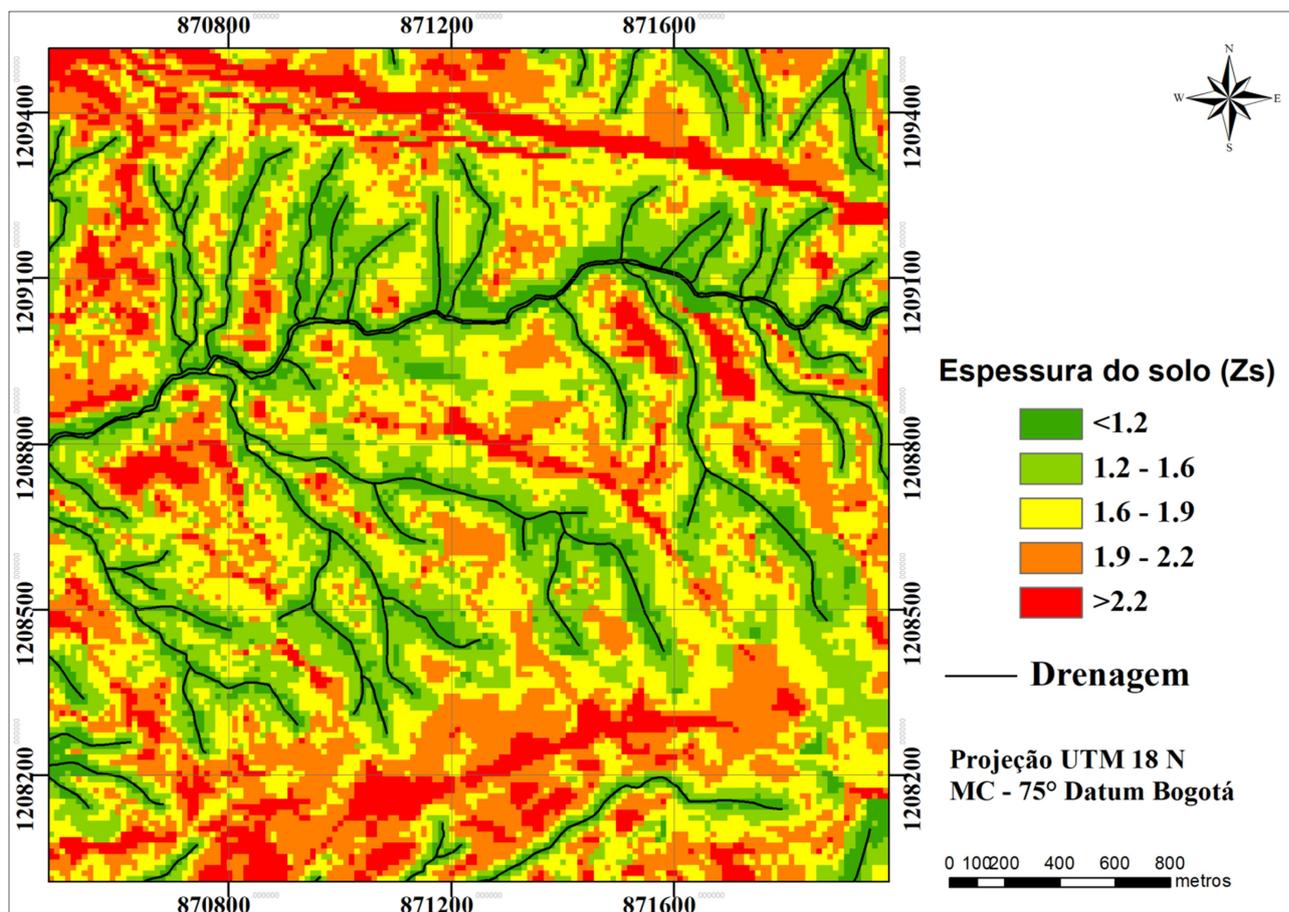


Figura 4.2. Mapa de espessura do solo

4.2 CHUVAS PARA O TREINAMENTO DA RNA

A RNA deve ser treinada com uma combinação abrangente de intensidade e durações, pelo qual, das curvas IDF apresentadas por Gomez (2002) foram selecionadas aleatoriamente cinco chuvas, apresentadas na Figura 3.6 e Tabela 4.1

Tabela 4.1. Eventos de chuva para treinamento validação e verificação do modelo de RNA

Tr (anos)	t (minutos)	I (mm/h)
5	5	151
5	100	48
50	50	94
100	5	243
100	100	77

As chuvas apresentadas na Tabela 6.1 seguem a premissa de Melo & Pedrollo (2015) e Pachepsky et al., (1996) quem sugerem que é possível treinar uma RNA desde que se tenha

uma base de dados abrangente, ou seja, uma base de dados onde todos os casos valores possíveis das variáveis são apresentados para o modelo de RNA no processo de treinamento e como pode ser visto na Figura 3.6 essas chuvas abrangem toda a curva IDF. No caso, a tabela 4.1 apresenta duas chuvas de baixa duração e alta intensidade, duas chuvas de baixa intensidade e alta duração e uma chuva intermediária.

4.3 CURVA CARACTERISTICA

Como não se tem dados experimentais para o município de Barbosa, do trabalho de Fresneda, C. (2017) foram obtidos dados laboratoriais para solos da mesma natureza e ajustados com a proposta de Cavalcante & Zornberg (2017) como apresentado nas Figuras 4.3 e 4.4

Tabela 4.2. Parâmetros hidráulicos. Fresneda, C. (2017)

Parâmetro	Argila siltosa (KcdA)	Areia Siltosa (Qdr)
θ_s	0,55	0,45
θ_r	3,07E-04	5,10E-06
δ	1,00E-03	9,00E-04

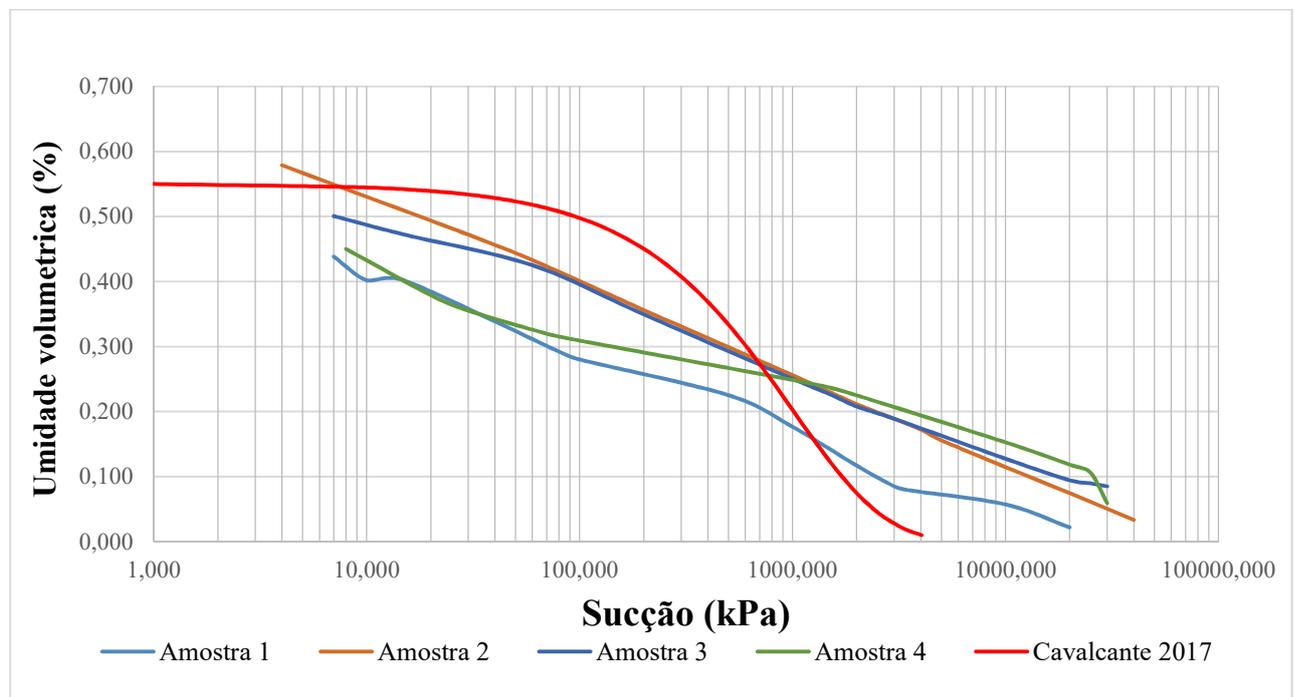


Figura 4.3. Curva característica solo-água depósito aluvial

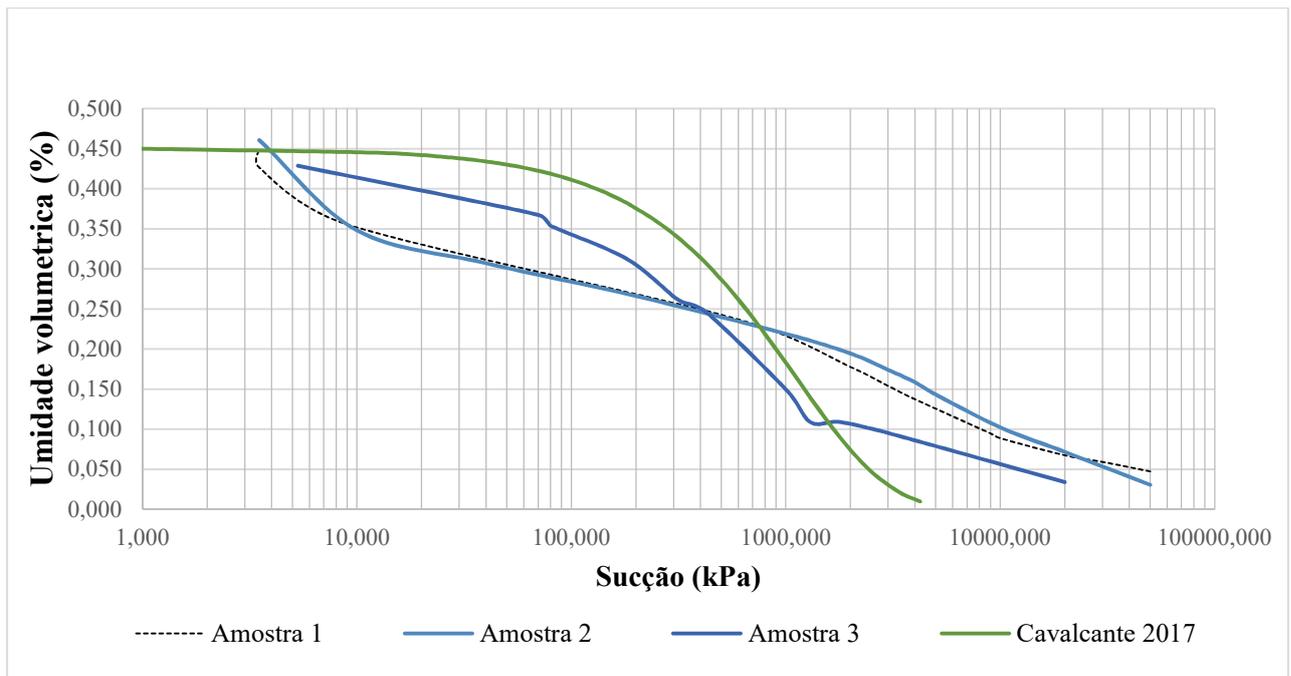


Figura 4.4. Curva característica solo água solo residual

Se justifica o uso de dados laboratoriais fora da área de estudo desde que sejam da mesma natureza, uma vez o que este trabalho tem por objetivo vislumbrar a capacidade das RNA em aprender e generalizar o problema. Se esse objetivo for confirmado posteriormente, seria possível treinar outra RNA com dados de qualquer área em interesse.

Como pode ser visto nas figuras 4.3 e 4.4, o modelo de Cavalcante & Zornberg (2017) consegue ajustar de forma aproximada os dados experimentais, mostrando ser um modelo eficiente para os solos da região. Cabe afirmar que o modelo empregado na aproximação é unimodal, essa aproximação poderia ser melhorada com modelos bimodais como o proposto por van Genuchten (1980)

4.4 ANALISES NUMÉRICAS DE INFILTRAÇÃO

A seguir, são apresentadas as combinações das variáveis para o treinamento da RNA produto da combinação de dois tipos de solo, três espessuras de superfície potencial de escorregamento, cinco chuvas, em termos de duração e intensidade, três declividades e três posições iniciais do lençol freático, como apresentado na tabela 4.3

Tabela 4.3. Variáveis para o treinamento do modelo de RNA

Tipos de solo	Espessuras (Z_s) de superfície potencial de escorregamento (m)	Chuvas			Declividades (graus)	Lençol freático - Z_s/Z_w - (%)
		Nº	t (minutos)	I (mm/h)		
Argila siltosa (KcdA)	1	1	5	151	10	30
		2	100	48		
Areia Siltosa (Qdr)	2	3	50	94	20	50
		4	5	243		
	3	5	100	77	30	70

Assim, combinando as variáveis para treinamento apresentadas na Tabela 4.3 surgem 270 casos ou simulações a serem feitas no software SEEP-W. As variáveis analisadas em para cada um dos 270 casos encontrassem no Anexo 1.. Na Figura 4.5 se apresenta de forma esquemática cada uma das variáveis que compõem cada caso.

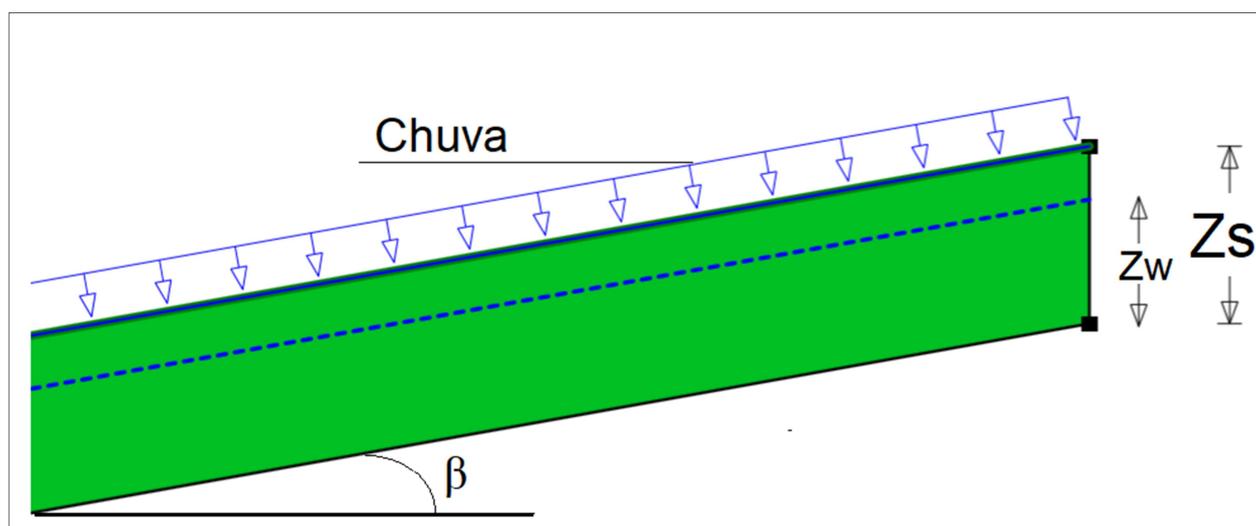


Figura 4.5. Esquematização geometria encosta

A combinação dessas variáveis apresenta por resultado 270 casos, cada um deles a ser simulado no módulo SEEP-W, obtendo como resposta o perfil de poropressão ao finalizar cada chuva. Com essa base de dados artificial será treinada e validada a capacidade da RNA de aprender o problema e dar uma resposta em termos da poropressão.

O Software SEEP-W fornece, como resultado, a variação da poropressão variando com a profundidade, como o exemplificado na Figura 4.6, onde para uma camada de solo de

1,0m e uma inclinação determinada é obtida dita variação ao finalizar uma das chuvas simuladas.

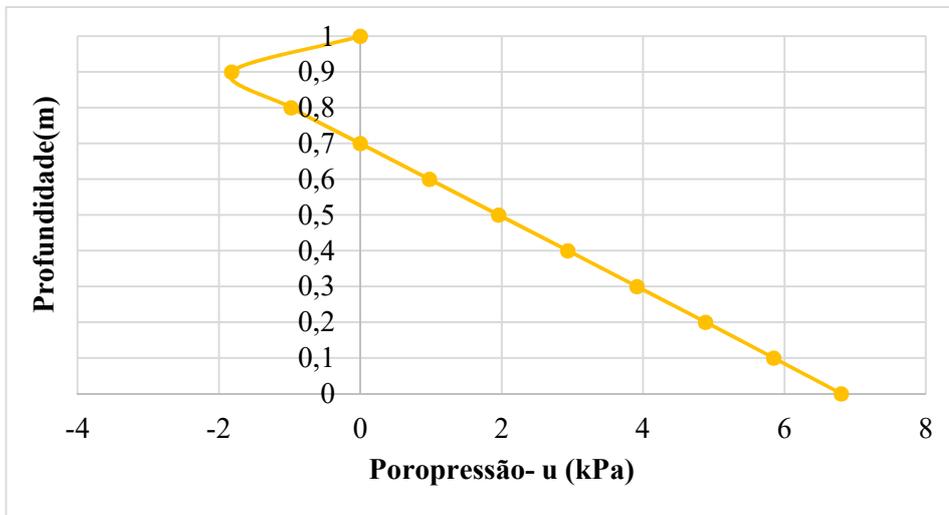


Figura 4.6. Modelo de perfil poropressão SEEP-W

Seria necessário uma RNA com muitos neurônios na cama de saída para obter um perfil “curvo” como o apresentado na Figura 4.6, razão pela qual se optou por “linearizar” o perfil (Figura 4.7) e treinar a RNA para que as saídas sejam o valor de sucção na base do perfil (profundidade 0m), profundidade onde a poropressão é igual a 0 kPa, e as coordenadas (poropressão, profundidade) para o menor valor de poropressão.

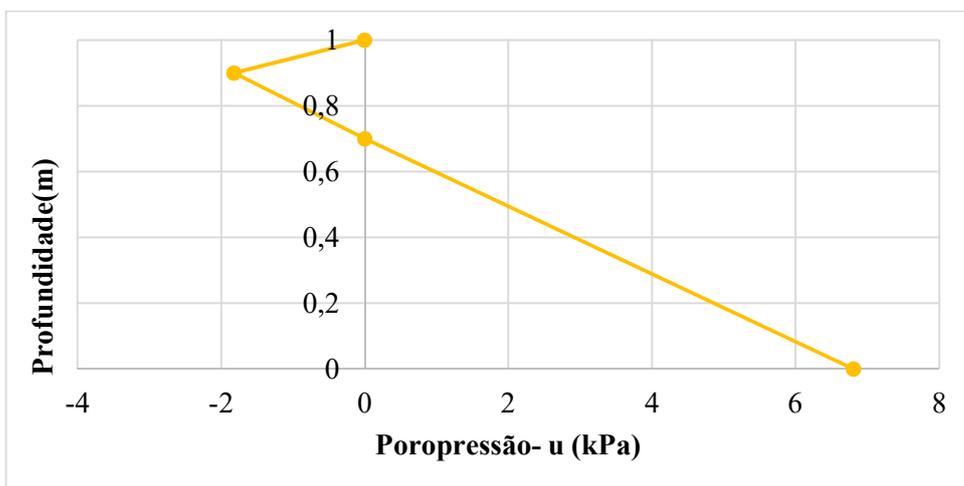


Figura 4.7. Modelo de perfil poropressão 'linearizado'

4.4.1 Escolha da malha de elementos finitos

A discretização do domínio foi feita de modo a minimizar o tempo de simulação, pelo software SEEP-W, foi fixado um único caso e feita a simulação com os mesmos parâmetros

hidráulicos mudando a quantidade de elementos da malha de elementos finitos começando com 1624 elementos e aumentando até 40640 elementos, na Figura 6.8 aparecem os resultados executando uma simulação com os mesmos dados de entrada e mudando a quantidade de elementos

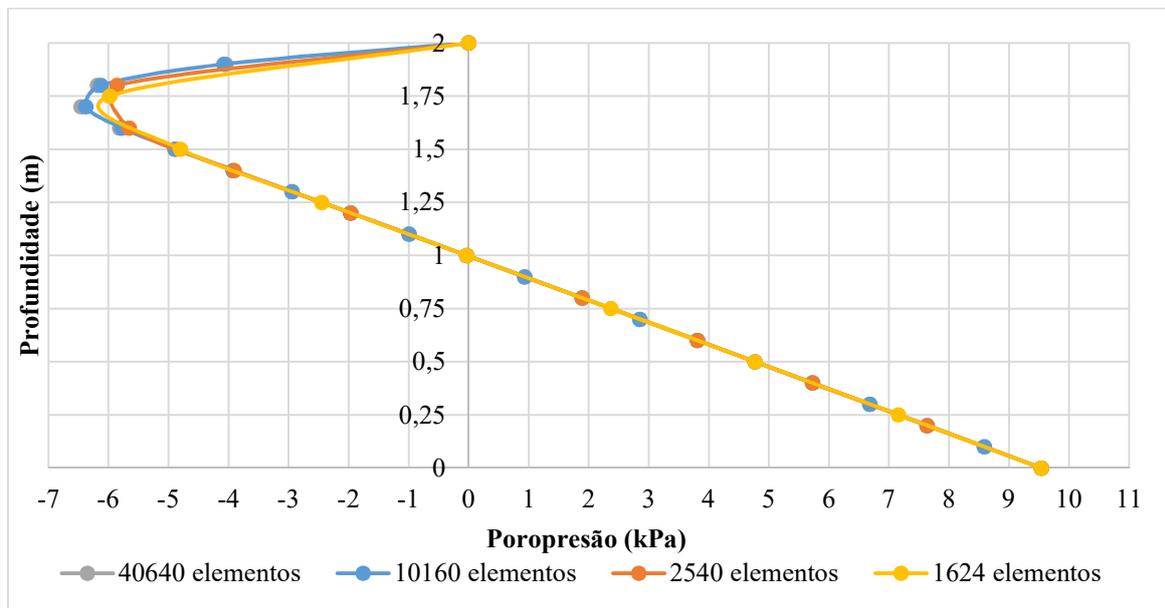


Figura 4.8. Escolha malha de elementos finitos

Pode-se então verificar que, a partir de 10160 elementos, o resultado da simulação se estabiliza, sendo um gasto computacional desnecessário aumentar o número de elementos, razão pela qual foi definido, como malha ótima para solução de problema estudado, uma malha quadrada com 10160 elementos para todos os casos.

4.4.2 ARQUITETURA E TREINAMENTO DO MODELO DE REDE NEURONAL

Para modelar a variação da poropressão com a profundidade em taludes submetidos a infiltrações, foram criadas duas redes do tipo MLP, uma para os solos argilo-siltosos e outra para os solos areno-siltosos, solos estes característicos da área de estudo, com duas camadas intermediárias de oito neurônios cada, uma camada de entrada com cinco neurônios e uma camada de saída com quatro neurônios. As redes foram treinadas usando o algoritmo Levenberg-Marquardt, implementado no programa MATLAB, cujo desempenho, em termos de erro quadrático mínimo com função de regularização de desempenho, mostrou-se melhor que outros algoritmos, como o gradiente descendente simples. Os 270 casos da base de dados

foram divididos aleatoriamente pelo software MATLAB nas seguintes porcentagens: 70% para treinamento, 15% para validação do treinamento e 15% para verificação do treinamento.

A utilização de uma RNA com duas camadas é justificada pelo fato de os neurônios tenderem a interagir entre si globalmente em redes de uma única camada, o que torna difícil melhorar a aproximação em um ponto sem piorá-la no outro. Já com duas camadas intermediárias, o processo torna-se mais gerenciável, pois as características locais são extraídas da primeira camada, na qual cada neurônio combina as saídas dos neurônios da primeira camada operando numa região particular do espaço (Haykin, 2001).

Já foi mencionada e justificada a utilização de uma rede com duas camadas intermediárias, porém nada foi dito ainda sobre o tamanho das mesmas. Em relação a esse assunto, somente pode ser dito que o tamanho foi escolhido de maneira aleatória, procurando que a rede fosse de tamanho pequeno considerando a relação entre as variáveis de entrada.

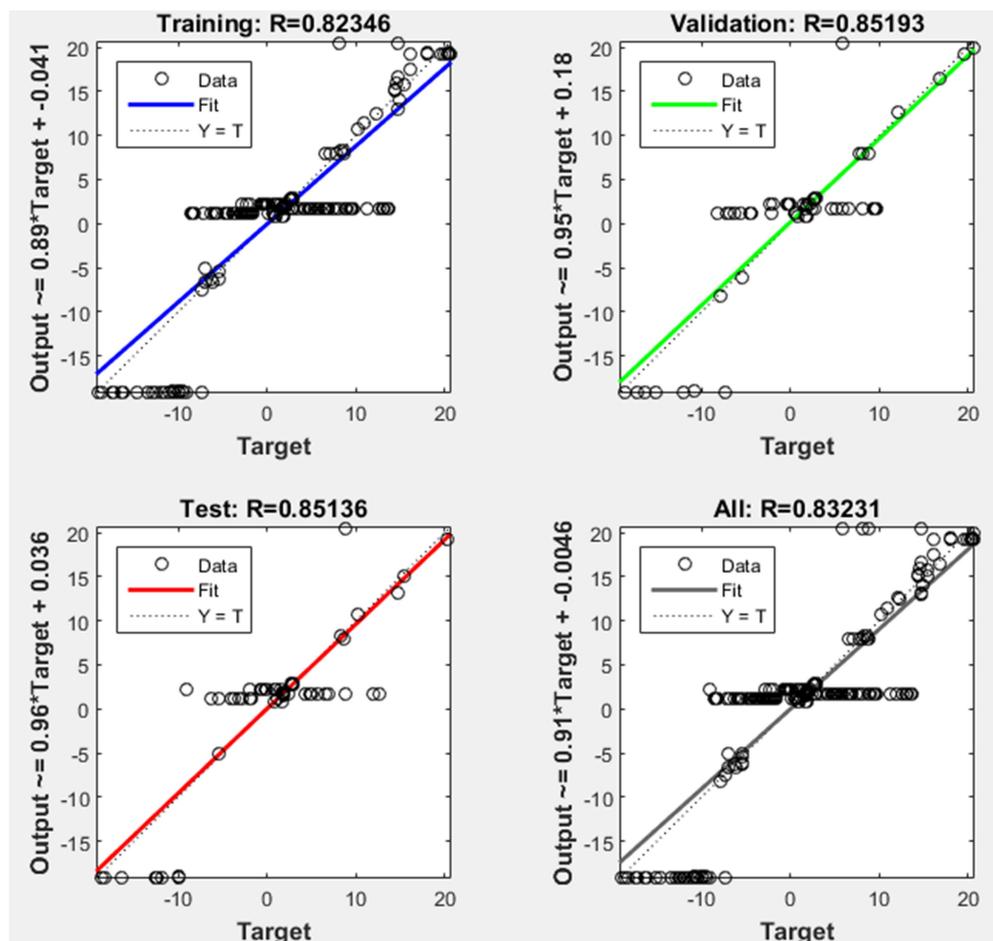


Figura 4.9. Resultados correlação RNA para argilas-siltosas

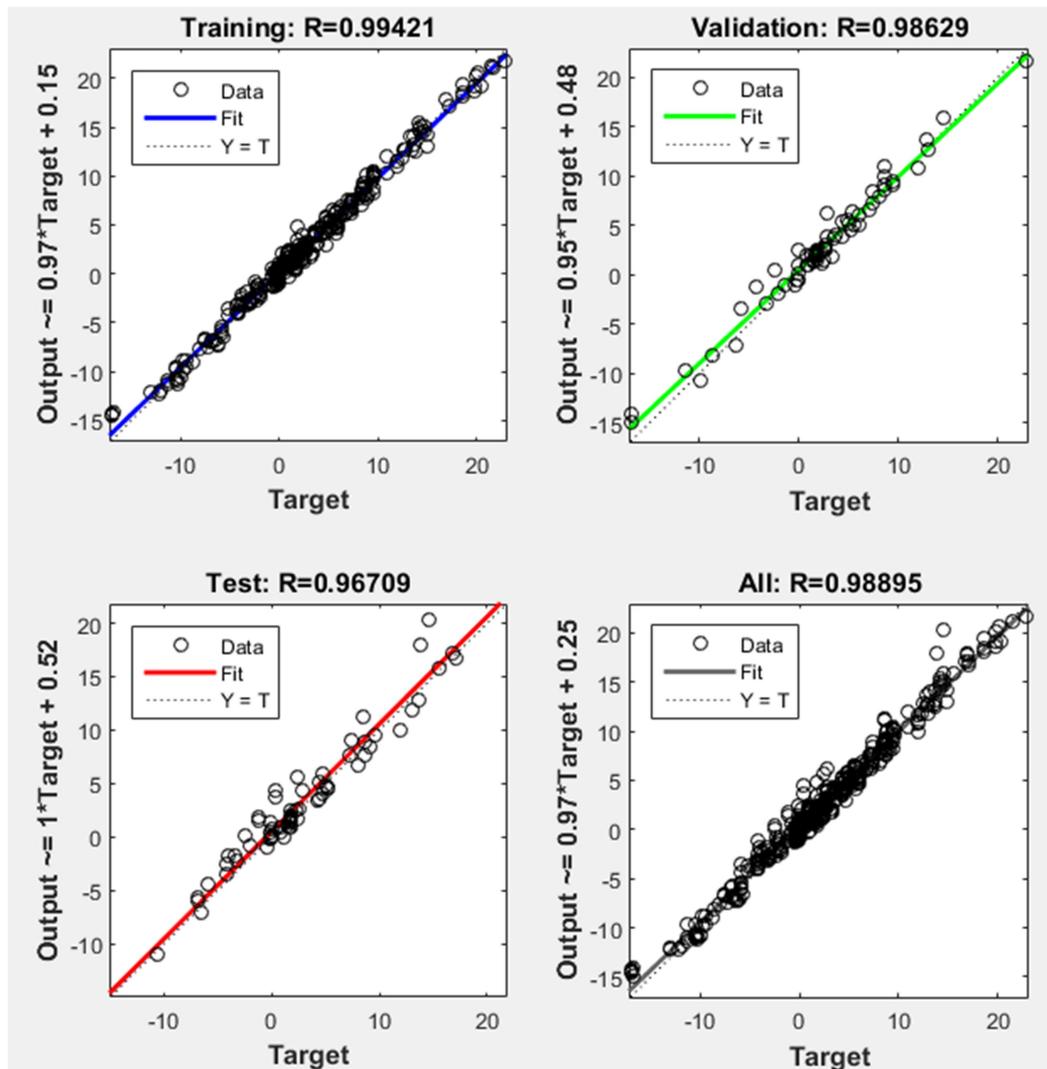


Figura 4.10. Resultados correlação RNA para areias-siltosas

Ressalta-se que, neste trabalho, o objetivo, mais do que buscar uma arquitetura ótima, era vislumbrar se a linha de trabalho indicada apresentava-se promissora e conseqüentemente determinar suas possibilidades futuras.

No Anexo 1 são apresentados os resultados (curvas de poropressão vs. profundidade) para os 270 casos em análise. São mostrados os perfis obtidos mediante simulação numérica e após o processo de “linearização”.

Os parâmetros das RNA obtidas são apresentados no Anexo 2

4.5 CALCULO DO FATOR DE SEGURANÇA

Para os 270 casos foram feitas análises de infiltração e obtido o perfil de poropressão *versus* profundidade. No Anexo 1, encontram-se os resultados. Uma vez que se tem o valor da poropressão ao finalizar cada chuva é possível, junto com os parâmetros de coesão, ângulo de atrito e peso específico especializados, aplicando a equação 5.10 obter uma estimativa do fator de segurança. Cabe dizer que a equação 5.10 não é a única que poderia ser aplicada, o usuário pode programar qualquer equação de talude infinito. No Anexo 3 é mostrado o código implementado para o calculo do fator de segurança.

4.6 MAPAS DE AMEAÇA

Com a finalidade de exemplificar e mostrar o potencial da RNA, foram escolhidas nove chuvas e calculado o fator de segurança (indicativo do potencial de ameaça) ao finalizar cada uma dessas chuvas na área de estudo, Tabela 4.4 e Figuras 4.11 a 4.19

O fator de segurança é comparado com a carta de inicio de escorregamentos de movimentos de massa da área de estudo, observados por AREA (2018)

Tabela 4.4. Chuvas para elaboração mapas de ameaça

Caso	D (min)	I (mm/h)	Zw (%)
1	10	70	30
2	10	70	50
3	10	70	70
4	90	70	30
5	90	70	50
6	90	70	70
7	15	200	30
8	15	200	50
9	15	200	70

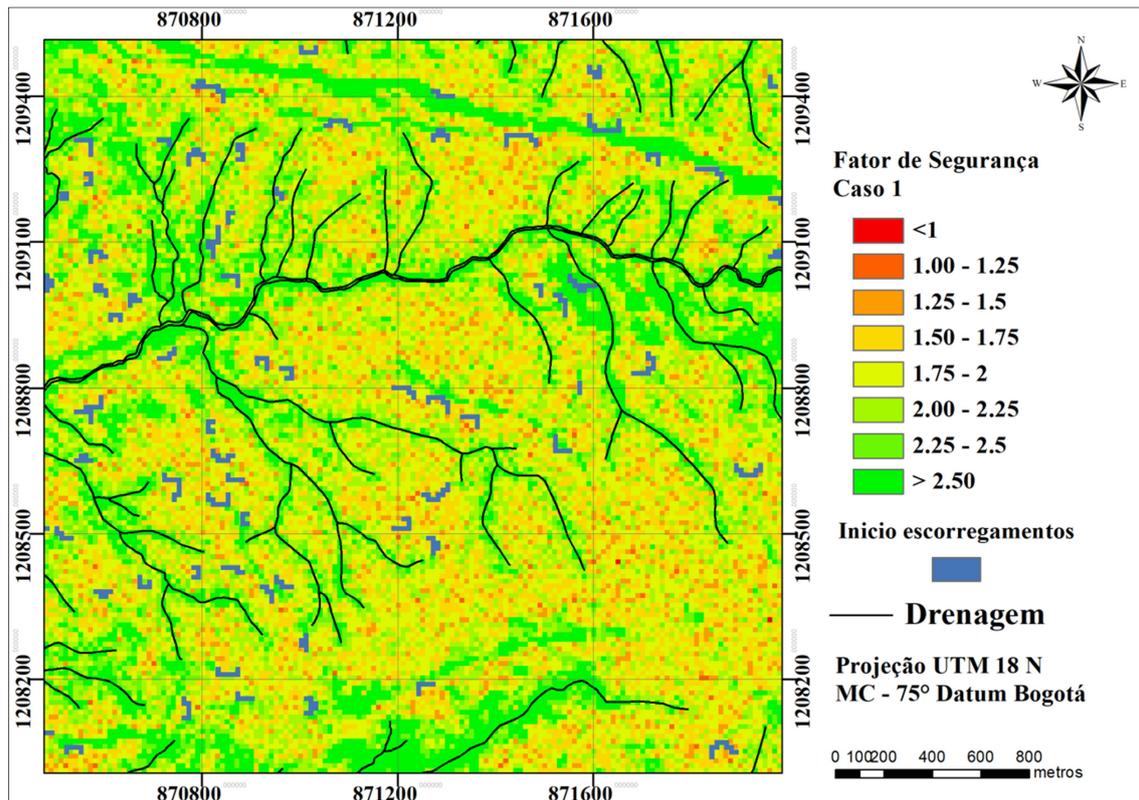


Figura 4.11. Fator de segurança caso 1

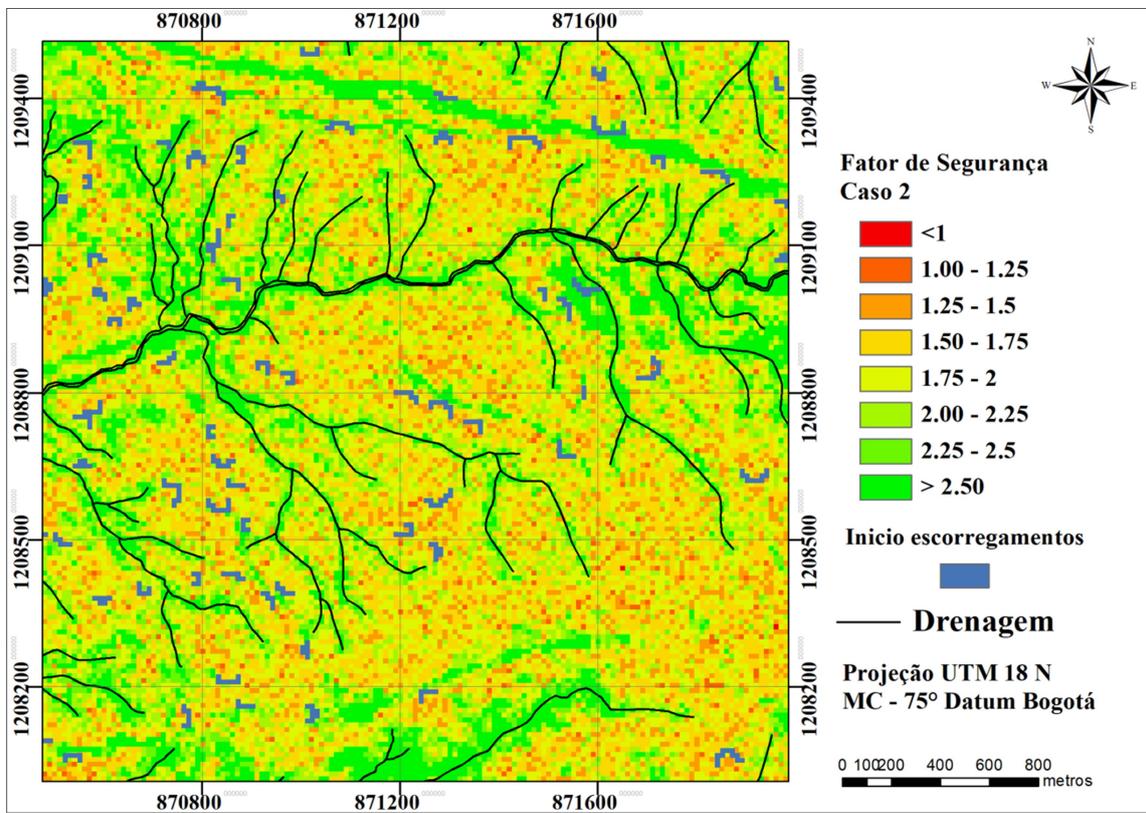


Figura 4.12. Fator de segurança caso 2

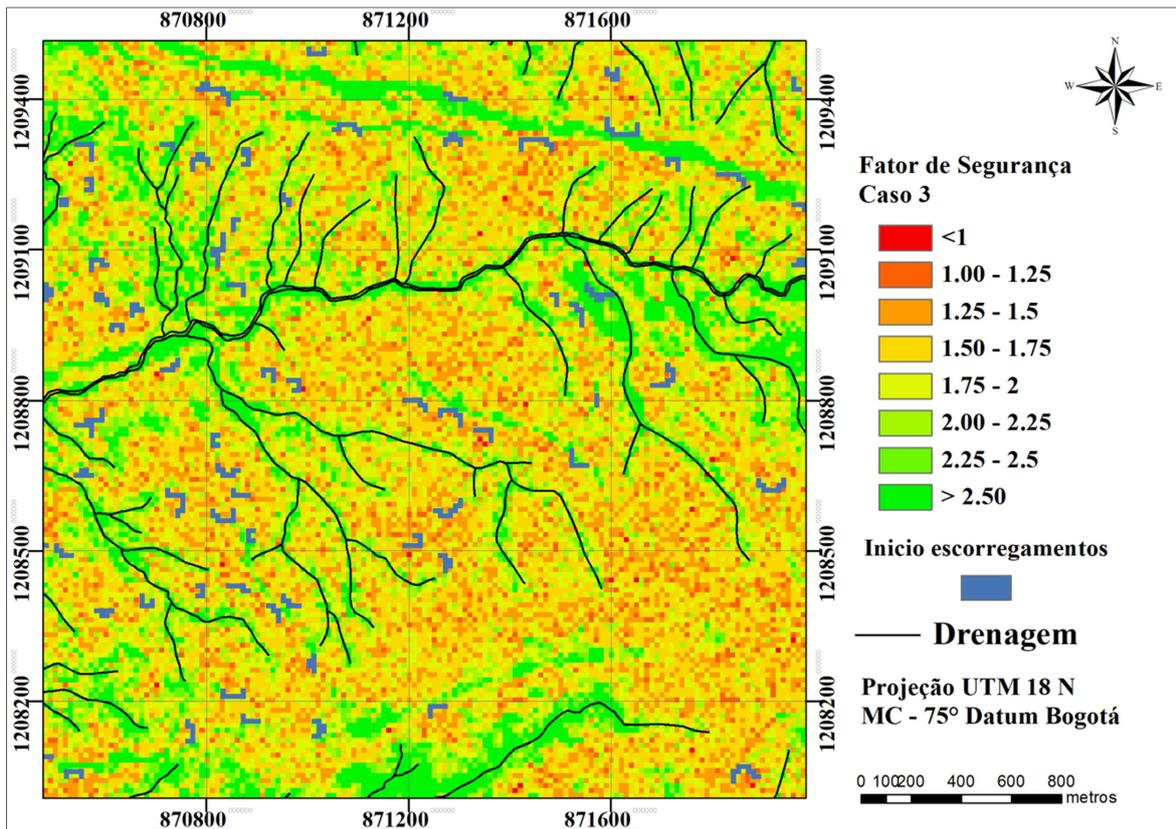


Figura 4.13. Fator de segurança caso 3

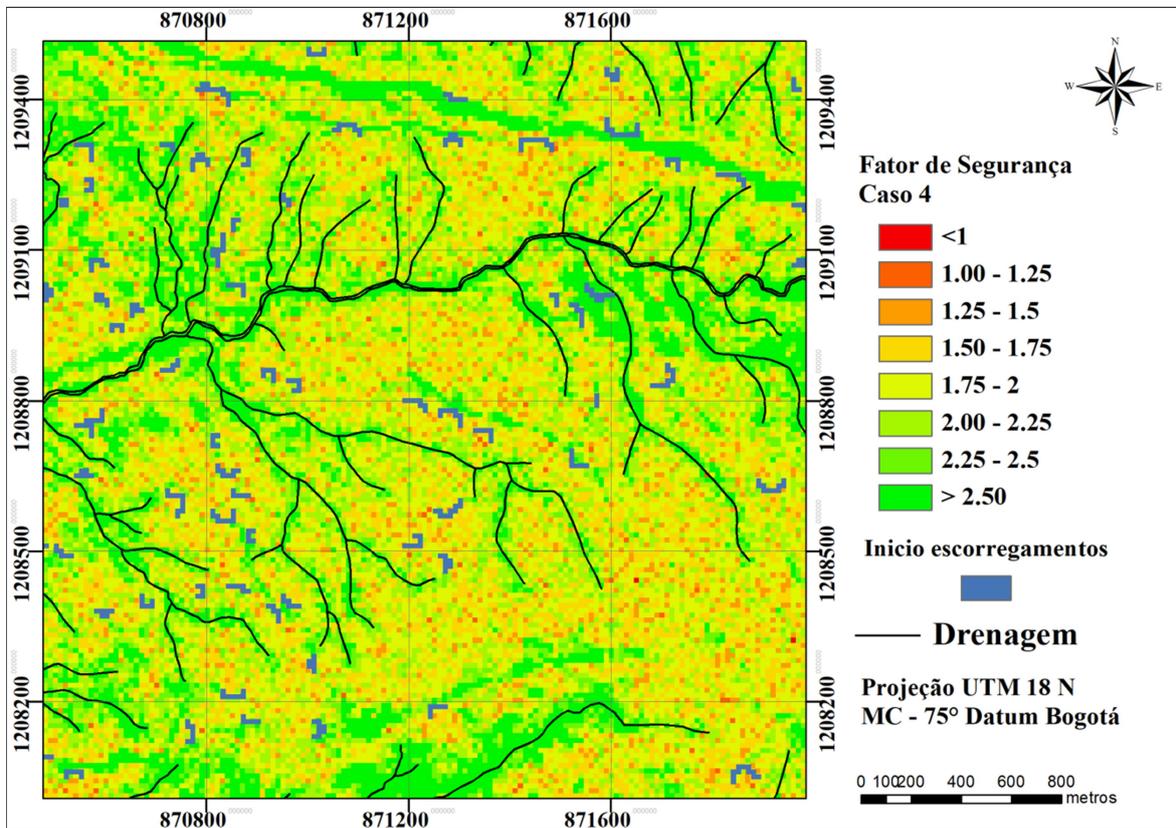


Figura 4.14. Fator de segurança caso 4

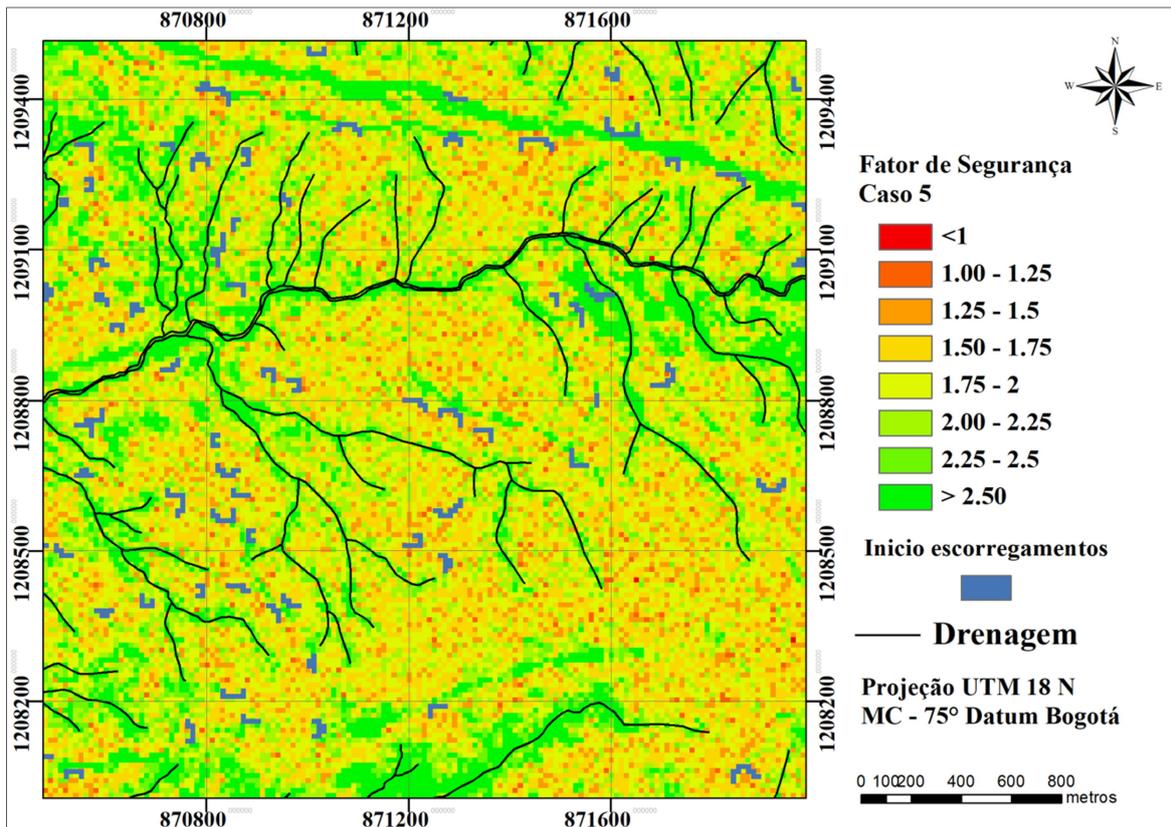


Figura 4.15. Fator de segurança caso 5

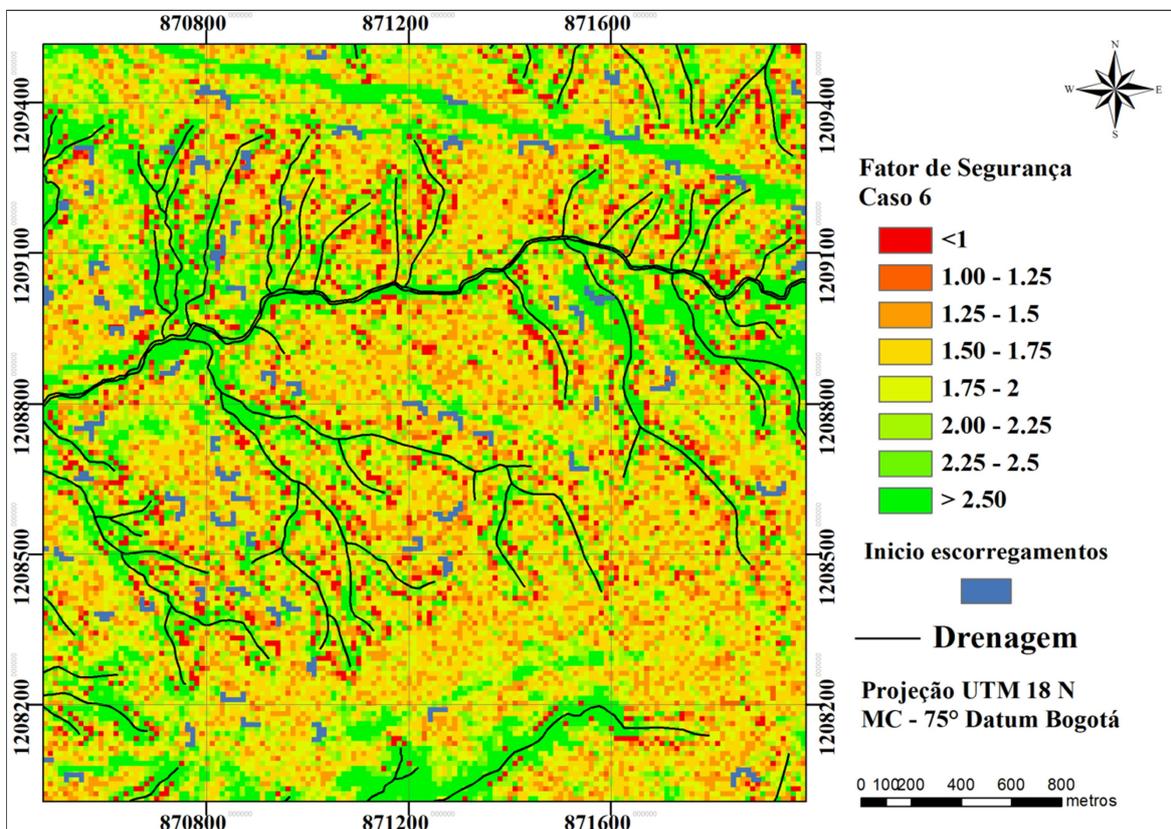


Figura 4.16. Fator de segurança caso 6

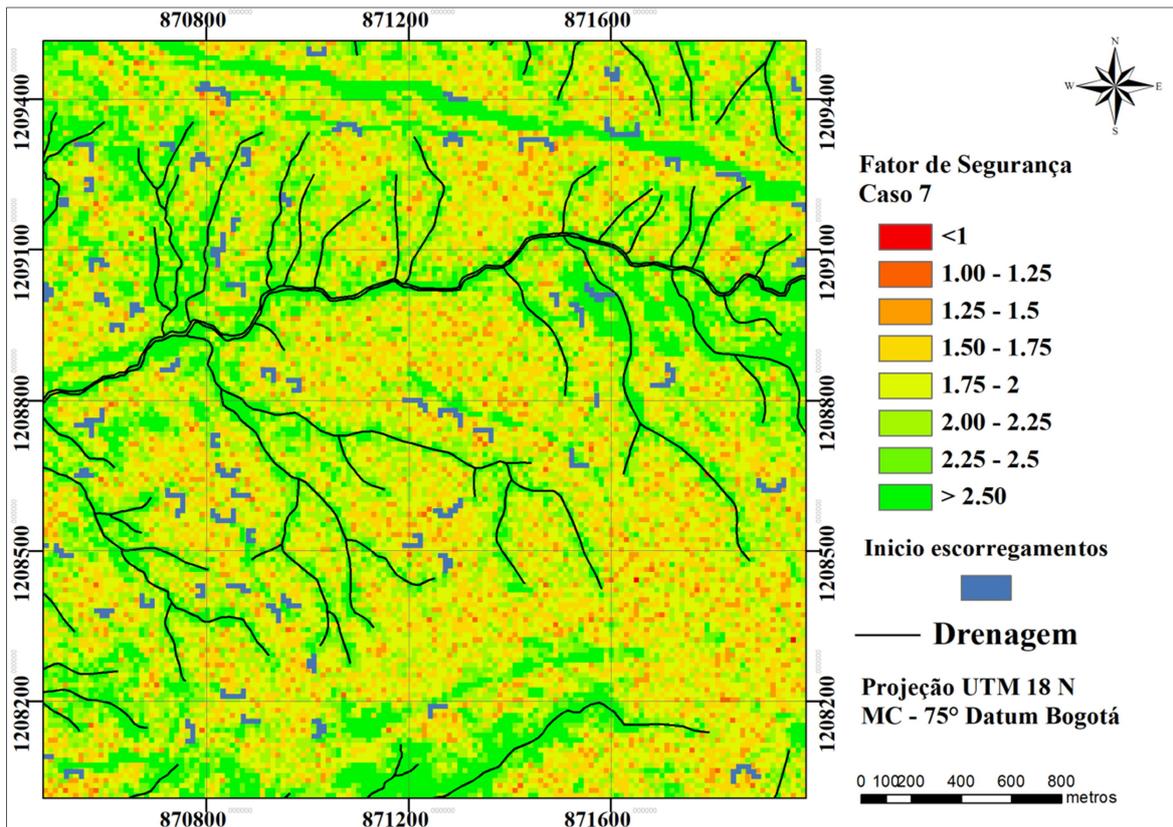


Figura 4.17. Fator de segurança caso 7

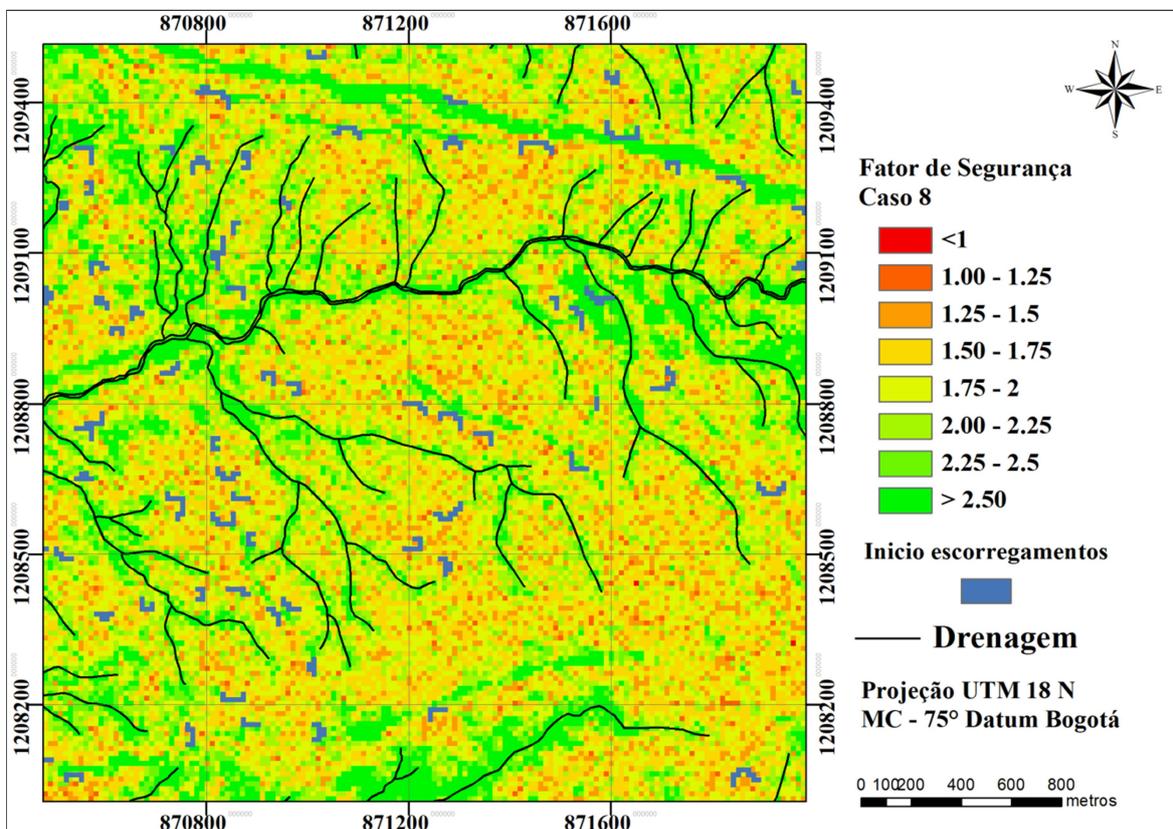


Figura 4.18. Fator de segurança caso 8

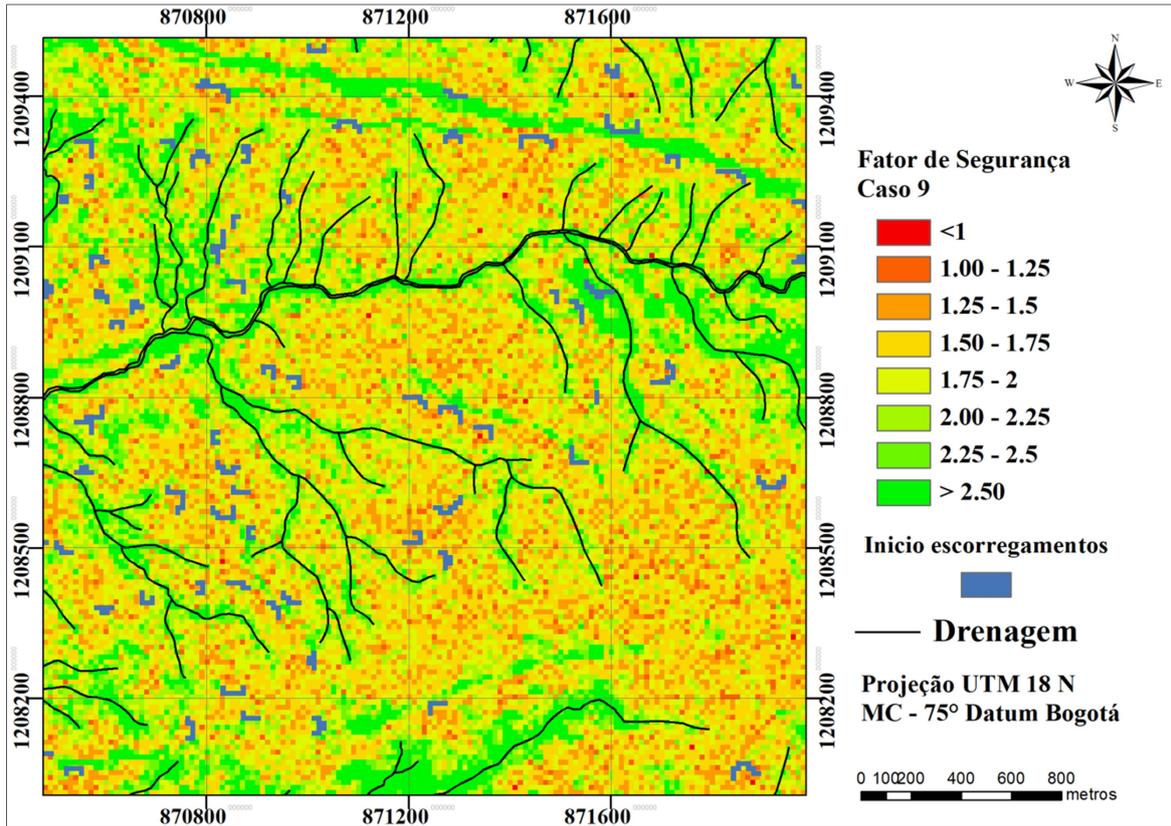


Figura 4.19. Fator de segurança caso 9

Tabela 4.5. Porcentagem de área acumulada

Caso	D (min)	I (mm/h)	Zw (%)	FS ≤ 1,0	1,0 < FS ≤ 1,25	1,25 < FS ≤ 1,5	1,5 < FS ≤ 1,75	1,75 < FS ≤ 2,0	2,0 < FS ≤ 2,25	2,25 < FS ≤ 2,5	FS > 2,5
1	10	70	30	0,01	0,32	4,54	18,78	26,90	19,85	10,96	18,64
2	10	70	50	0,02	1,06	8,88	24,53	26,17	15,61	8,37	15,36
3	10	70	70	0,13	2,72	14,85	28,38	22,03	11,92	6,46	13,50
4	90	70	30	0,01	0,28	4,37	18,79	27,56	20,31	10,70	17,97
5	90	70	50	0,02	0,75	7,45	23,89	27,66	16,52	8,57	15,14
6	90	70	70	5,02	3,66	12,77	23,60	19,58	11,41	6,39	17,57
7	15	200	30	0,01	0,33	4,55	18,76	26,89	19,79	10,85	18,81
8	15	200	50	0,01	0,88	8,10	23,87	26,44	16,36	8,74	15,60
9	15	200	70	0,07	2,07	12,80	27,74	23,47	13,00	6,88	13,98

5 CONCLUSÕES E RECOMENDAÇÕES

A seguir são expostas as conclusões gerais sobre a metodologia aqui descrita:

- Encontrou-se uma equação simples que descreve o comportamento da variável espessura da camada potencial de solo a ser deslizado envolvendo variáveis do meio físico e de fácil determinação. Essa equação pode ser empregada em qualquer estudo de ameaça ou vulnerabilidade, uma vez que as variáveis de entrada são de fácil e rápida obtenção.
- Uma RNA foi treinada com um banco de dados artificialmente elaborado onde declividades, espessuras da camada potencial a se deslizar e precipitações típicas da área de estudo foram as entradas e a variação da poropressão com a profundidade ao finalizar uma determinada chuva a saída.
- O modelo de RNA apresentado se mostrou como uma ferramenta de fácil aplicação, mostrando que é um instrumento válido a ser incorporado em sistemas de alerta de escorregamentos superficiais deflagrados por chuvas. O tempo de treinamento das RNA variou de 0,5 até 3,0 segundos quando empregado um PC com processador Intel® Core™ i7 – 7700 CPU @ 3600 GHz e memória RAM de 64GB
- O uso de RNA se mostrou como uma metodologia poderosa para avaliar a ameaça de movimentos de massa em grandes áreas, como a da área de aplicação, na qual uma estimativa analítica do fator de segurança torna-se impossível devido à necessidade de discretização e conseqüentemente o grande número de pixels que representaria o número de repetições do cálculo.
- Papa *et al.* (2013) propõe uma representação comparativa de curvas IDF com valores de porcentagem de área falhada para uma posição inicial do lençol freático fixa como a mostrada na Figura 5.1 na qual, para uma chuva de alta duração e baixa intensidade se produz uma maior porcentagem de área falhada do que para baixas durações e altas intensidades.

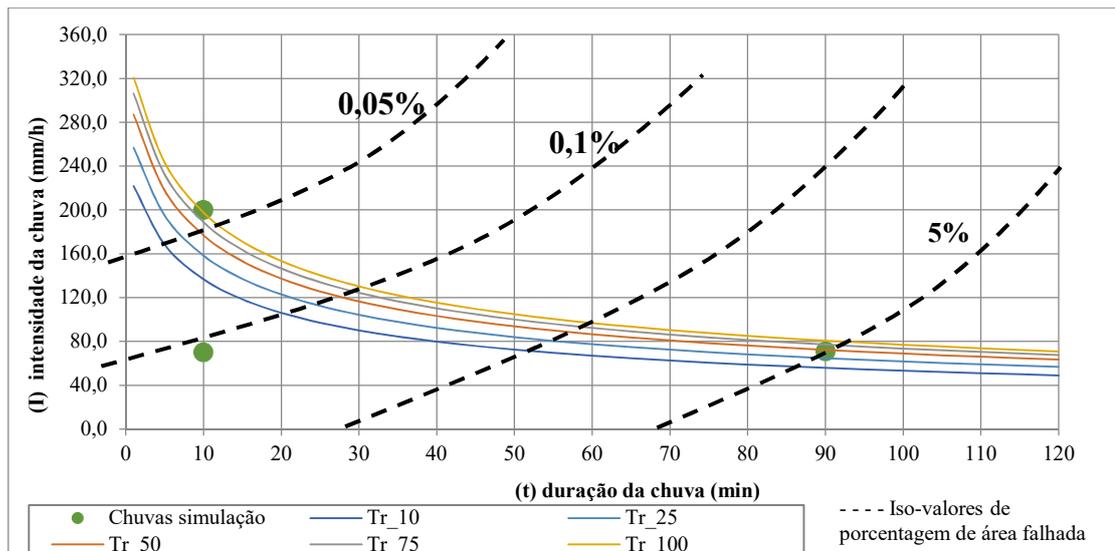


Figura 5.1. Iso-valores de porcentagem de área falhada

É possível então, para uma determinada área em estudo gerar Figuras como a 5.1 a qual consegue corroborar que chuvas de alta duração e baixa intensidade geram maior prejuízo em termos de área falhada quando comparado com chuvas de baixa duração e alta intensidade.

- Pesquisas desta natureza mostram-se de extrema importância no sentido que proporcionam a geração de elementos voltados para a caracterização ambiental, o que é pertinente a estudos de diversas naturezas, servindo de insumo para análises voltadas desde temas amplos a ramos específicos, como estabilidade de encostas.
- A aplicação da metodologia se mostrou como uma ferramenta válida e de fácil aplicação em projetos que procuram nortear o cálculo da ameaça em grandes regiões, facilitando a tomada de decisões.
- A técnica de RNA mostrou ter uma grande habilidade de interpolar os dados do problema estudado. Uma vez que se tem uma base de dados inicial é possível, posteriormente, incrementar essa base de dados com outras informações consideradas relevantes para estudos voltados a determinação de ameaça por escorregamentos superficiais em grandes áreas e melhorar a aproximação obtida pelo modelo.
- A metodologia pode ser extrapolada a outras zonas, outros tipos e distribuições de chuva com a finalidade de obter parâmetros que permitam avaliar a ameaça de encostas submetidas a processos de infiltração.

- Novos elementos condizentes a aspectos geomorfológicos ou hidrológicos do terreno podem ser incorporados em abordagens futuras na tentativa de conduzir a uma representação mais aprimorada da camada potencial a ser escorregada.
- Sugere-se ampliar as entradas do modelo de RNA de forma a incluir a influencia da permeabilidade do solo em questão.

6 REFERÊNCIAS

- Adeli, H. (2001). Neural Networks in Civil Engineering: 1989-2000. *Computer-Aided Civil and Infrastructure Engineering*, 16(2), 126–142. <http://doi.org/10.1111/0885-9507.00219>
- Aleotti, P., & Chowdhury, R. (1999). Landslide hazard assessment: summary review and new perspectives. *Bulletin of Engineering Geology and the Environment*, 58(1), 21–44. <http://doi.org/10.1007/s100640050066>
- Anderson, S. a, & Sitar, N. (1995). Analysis of Rainfall-Induces debris flows. *Journal of Geotechnical Engineering*, 121(7), 544–552. [http://doi.org/10.1061/\(ASCE\)0733-9410\(1995\)121:7\(544\)](http://doi.org/10.1061/(ASCE)0733-9410(1995)121:7(544))
- AREA (2002). Micro Zonation for Eathquakes in the Aburrá Valley Localities and Risk for Landslides and Flooding Definiton (In Spanish), Medellín, Colombia, 213p.
- AREA (2018) Actualización de la amenaza por movimientos em masa, inundaciones y avenidas torrenciales de algunos municipios del Área Metropolitana del Valle de Aburra, InPress.
- Aristizábal, E., González, T., Montoya, J., Vélez, J., Martínez, H., & Guerra, A. (2011). Analysis of empirical rainfall thresholds for the prognosis of lanslides in the Aburrá Valley, Colombia. *Revista EIA*, 8(15), 95–111.
- Aristizábal, E., Martínez, H., & Vélez, J. I. I. (2010). Una revisión sobre el estudio de movimientos en masa detonados por lluvias. *Revista de La Academia Colombiana de Ciencias*, 34(53), 209–227.
- Aristizábal, E., Vélez, J. I., Martínez, H. E., & Jaboyedoff, M. (2016). SHIA_Landslide: a distributed conceptual and physically based model to forecast the temporal and spatial occurrence of shallow landslides triggered by rainfall in tropical and mountainous basins. *Landslides*. <http://doi.org/10.1007/s10346-015-0580-7>
- Biswajeet, P., & Saro, L. (2007). Utilization of Optical Remote Sensing Data and GIS Tools for Regional Landslide Hazard Analysis Using an Artificial Neural Network Model. *Earth Science Frontiers*, 14(6), 143–151. [http://doi.org/10.1016/S1872-5791\(08\)60008-1](http://doi.org/10.1016/S1872-5791(08)60008-1)
- Borga, M., Dalla Fontana, G., Da Ros, D., & Marchi, L. (1998). Shallow landslide hazard assessment using a physically based model and digital elevation data. *Environmental Geology*, 35(2–3), 81–88. <http://doi.org/10.1007/s002540050295>
- Botero, E. M., Azevedo, G. F., Carvajal, H. E. M., Garc?a, E. F., & Azevedo, G. F. (2016). The Use of Neural Networks to Forecast Landslides Triggered by Rains in Mountainous Areas. In *Geo-Chicago 2016* (Vol. 2007, pp. 422–429). Reston, VA: American Society of Civil Engineers. <http://doi.org/10.1061/9780784480120.043>
- Botero, E. M., AZEVEDO, G. F., Eduardo, C. H., SOUZA, N. M. de, & ARISTIZÁBAL, G. E. F. (2015). Estimativa Espacial da Profundidade do Solo com Aplicação em Estabilidade de Taludes. In *Proceedings of the 15th Pan-American Conference on Soil Mechanics and Geotechnical Engineering, 15–18 November 2015* (pp. 3113–3120). Buenos Aires, Argentina. <http://doi.org/10.3233/978-1-61499-603-3-3113>
- Botero, E. M., Azevedo, G. F., Souza, H. E. M. C., De Souza, N. M., & Aristizabal, E. F. G. (2015). Estimativa da profundidade do solo pelo uso de técnicas de geoprocessamento, estudo de caso: Setor Pajarito, Colômbia. In *Anais XVII Simpósio Brasileiro de Sensoriamento Remoto - SBSR, João Pessoa-PB, Brasil, 25 a 29 de abril de 2015, INPE* (pp. 4551–4558). <http://doi.org/10.1017/CBO9781107415324.004>
- Camapum de Carvalho, J., G. J., & G., L. (2012). *Tópicos Sobre Infiltração: Teoria e Pratica Aplicada a solos tropicais*. Brasilia-DF: Facudade de Tecnologia - UnB.

- Caniani, D., Pascale, S., Sdao, F., & Sole, A. (2008). Neural networks and landslide susceptibility: A case study of the urban area of Potenza. *Natural Hazards*, 45(1), 55–72. <http://doi.org/10.1007/s11069-007-9169-3>
- Cavalcante, A. L. B., & Zornberg, J. G. (2017). Efficient Approach to Solving Transient Unsaturated Flow Problems. I: Analytical Solutions. *International Journal of Geomechanics*, 04017013. [http://doi.org/10.1061/\(ASCE\)GM.1943-5622.0000875](http://doi.org/10.1061/(ASCE)GM.1943-5622.0000875)
- Chacón, J., Irigaray, C., Fernández, T., & El Hamdouni, R. (2006). Engineering geology maps: Landslides and geographical information systems. *Bulletin of Engineering Geology and the Environment*, 65(4), 341–411. <http://doi.org/10.1007/s10064-006-0064-z>
- Chae, B. G., Lee, J. H., Park, H. J., & Choi, J. (2015). A method for predicting the factor of safety of an infinite slope based on the depth ratio of the wetting front induced by rainfall infiltration. *Natural Hazards and Earth System Sciences*, 15(8), 1835–1849. <http://doi.org/10.5194/nhess-15-1835-2015>
- Cho, S. E., & Lee, S. R. (2002). Considering Rainfall Characteristics. *Evaluation of Surficial Stability for Homogeneous Slopes Considering Rainfall Characteristics*, 128(9), 756–763. [http://doi.org/10.1061/\(ASCE\)1090-0241\(2002\)128:9\(756\)](http://doi.org/10.1061/(ASCE)1090-0241(2002)128:9(756))
- Crosta, G. (1998). Regionalization of rainfall thresholds: An aid to landslide hazard evaluation. *Environmental Geology*, 35(2–3), 131–145. <http://doi.org/10.1007/s002540050300>
- Cruden, D. M., & Varnes, D. J. (1996). *Landslides, Investigation and Mitigation. Landslide types and processes Bussines Office. Washington, DC Transportation Research Board. Washington DC, USA, 36-75 p.*
- Dai, F. ., Lee, C. ., & Ngai, Y. . (2002). Landslide risk assessment and management: an overview. *Engineering Geology*, 64(1), 65–87. [http://doi.org/10.1016/S0013-7952\(01\)00093-X](http://doi.org/10.1016/S0013-7952(01)00093-X)
- de Blasio, F. V. (2011). *Introduction to the Physics of Landslides*. HEIDELBERG: Springer Netherlands. <http://doi.org/10.1007/978-94-007-1122-8>
- Duncan, J. Michael, Stephen G. Wright. (2014). *Soil strength and slope stability*. (J. W. & Sons, Ed.).
- Duncan, J. M., Wright, S. G., & Brandon, T. L. (2014). *Soil strength and slope stability. Changes*.
- Ermini, L., Catani, F., & Casagli, N. (2005). Artificial Neural Networks applied to landslide susceptibility assessment. *Geomorphology*, 66(1–4 SPEC. ISS.), 327–343. <http://doi.org/10.1016/j.geomorph.2004.09.025>
- Fell, R., Corominas, J., Bonnard, C., Cascini, L., Leroi, E., & Savage, W. Z. (2008). Guidelines for landslide susceptibility, hazard and risk zoning for land-use planning. *Engineering Geology*, 102(3–4), 99–111. <http://doi.org/10.1016/j.enggeo.2008.03.014>
- Fredlund, D. G., Morgenstern, N. R., & Widger, R. A. (1978). Canadian Geotechnical Revue canadienne. *Canadian Geotechnical Journal*, 15, 313–321.
- Fredlund, D. G., & Xing, A. (1994). Equations for the soil-water characteristic curve. *Canadian Geotechnical Journal*, 31(6), 1026–1026. <http://doi.org/10.1139/t94-120>
- Fresneda, C. (2017). Determinación de la Curva Caracerística Con Base en Propiedades Índice a suelos de Antioquia. Departamento de Ingeniería Civil, Universidad Nacional de Colombia, InPress.
- GeoRio. (1999). *Análise da estabilidade de taludes em solo. Manual Técnico de Encostas*. (GeoRio, Ed.). Rio de Janeiro, RJ.
- Guzzetti, F., Mondini, A. C., Cardinali, M., Fiorucci, F., Santangelo, M., & Chang, K. T. (2012). Landslide inventory maps: New tools for an old problem. *Earth-Science Reviews*, 112(1–2), 42–66.

- <http://doi.org/10.1016/j.earscirev.2012.02.001>
- Hjerdt, K. N. (2004). A new topographic index to quantify downslope controls on local drainage. *Water Resources Research*, 40(5), 1–6. <http://doi.org/10.1029/2004WR003130>
- Iverson, R. M. (2000). Landslide triggering by rain infiltration. *Water Resources Research*, 36(7), 1897. <http://doi.org/10.1029/2000WR900090>
- Korup, O., & Clague, J. J. (2009). Natural hazards, extreme events, and mountain topography. *Quaternary Science Reviews*, 28(11–12), 977–990. <http://doi.org/10.1016/j.quascirev.2009.02.021>
- Larsen, M. C., & Rainfall-triggered, M. C. L. (2008). mitigation strategies To cite this version : Geosciences Rainfall-triggered landslides , anthropogenic hazards , and mitigation strategies.
- Luis, I., Gómez, A., Jorge, I., Aristizabal, A., Jorge, I. N. G., & Aristizabal, A. (2002). Obtencion de Curvas de Intensidad - Frecuencia - Duración para el Departamento de Caldas. *Universidad Nacional de Colombia*.
- Malamud, B. D., Turcotte, D. L., Guzzetti, F., & Reichenbach, P. (2004). Landslides, earthquakes, and erosion. *Earth and Planetary Science Letters*, 229(1–2), 45–59. <http://doi.org/10.1016/j.epsl.2004.10.018>
- Melo, T. M. De, & Pedrollo, O. C. (2015). Artificial Neural Networks for Estimating Soil Water Retention Curve Using Fitted and Measured Data, 2015.
- Michel, G. P. (2015). *ESTIMATIVA DA PROFUNDIDADE DO SOLO E SEU EFEITO NA MODELAGEM DE ESCORREGAMENTOS*. Universidade Federal do Rio Grande do Sul.
- Montgomery, D. R., & Dietrich, W. E. (1994). A physically based model for the topographic control on shallow landsliding. *Water Resources Research*, 30(4), 1153–1171. <http://doi.org/10.1029/93WR02979>
- Montoya, E. (2013). *Modelo de alerta de escorregamentos deflagrados por chuvas usando redes neurais artificiais*. UNIVERSIDADE DE BRASÍLIA FACULDADE.
- Montrasio, L., & Valentino, R. (2008). A model for triggering mechanisms of shallow landslides. *Natural Hazards and Earth System Science*, 8(5), 1149–1159. <http://doi.org/10.5194/nhess-8-1149-2008>
- Morgenster, N. R., & Price, V. E. (1965). The Analysis of the Stability of general slope surfaces. *Geotechnique*, 15(1), 725–726. <http://doi.org/10.1680/geot.1965.15.1.79>
- Muntohar, A. S., & Liao, H. J. (2010). Rainfall infiltration: Infinite slope model for landslides triggering by rainstorm. *Natural Hazards*, 54(3), 967–984. <http://doi.org/10.1007/s11069-010-9518-5>
- Neaupane, K. M., & Achet, S. H. (2004). Use of backpropagation neural network for landslide monitoring: A case study in the higher Himalaya. *Engineering Geology*, 74(3–4), 213–226. <http://doi.org/10.1016/j.enggeo.2004.03.010>
- Neaupane, K. M., & Piantanakulchai, M. (2006). Analytic network process model for landslide hazard zonation. *Engineering Geology*, 85(3–4), 281–294. <http://doi.org/10.1016/j.enggeo.2006.02.003>
- Networks, N., By, P., Kartam, N., & Members, A. (1994). Neural networks in civil engineering, 8(2), 131–148.
- Ni, S. H., Lu, P. C., & Juang, C. H. (1996). A fuzzy neural network approach to evaluation of slope failure potential. *Computer-Aided Civil and Infrastructure Engineering*, 11(1), 59–66. [http://doi.org/10.1016/0148-9062\(96\)81903-6](http://doi.org/10.1016/0148-9062(96)81903-6)
- Pachepsky, Y. A., Timlin, D., & Varallyay, G. (1996). Artificial Neural Networks to Estimate Soil Water Retention from Easily Measurable Data. *Soil Science Society of America Journal*, 60(3), 727. <http://doi.org/10.2136/sssaj1996.03615995006000030007x>
- Papa, M. N., Medina, V., Ciervo, F., & Bateman, A. (2013). Derivation of critical rainfall thresholds for shallow

- landslides as a tool for debris flow early warning systems. *Hydrology and Earth System Sciences*, 17(10), 4095–4107. <http://doi.org/10.5194/hess-17-4095-2013>
- Pijanowski, B. C., Brown, D. G., Shellito, B. A., & Manik, G. A. (2002). Using neural networks and GIS to forecast land use changes: A Land Transformation Model. *Computers, Environment and Urban Systems*, 26(6), 553–575. [http://doi.org/10.1016/S0198-9715\(01\)00015-1](http://doi.org/10.1016/S0198-9715(01)00015-1)
- Polemio, M., & Petrucci, O. (2000). Rainfall as a Landslide Triggering Factor: An Overview of Recent International Research. *The 8th International Symposium on Landslides in Cardiff, UK*, 3, 8 pages.
- Pradhan, B., & Lee, S. (2009). Landslide risk analysis using artificial neural network model focussing on different training sites. *International Journal of Physical Sciences*, 4(1), 1–15. Retrieved from <http://www.academicjournals.org/IJPS>
- Pradhan, B., & Lee, S. (2010). Regional landslide susceptibility analysis using back-propagation neural network model at Cameron Highland, Malaysia. *Landslides*, 7(1), 13–30. <http://doi.org/10.1007/s10346-009-0183-2>
- Ramos. (2003). *A Modelagem Matemática no Estudo de Movimentos de Massa: Aplicação de um Modelo de Previsão de Áreas Susceptíveis a Escorregamentos Rasos na Área do Subúrbio Ferroviário de Salvador*. Universidade de Brasília.
- Rojas, K.R.C. (2017). Estudo Dos Deslizamentos Superficiais Deflagrados Por Chuvas Implementando a Análise Não Saturada e Transiente em Escala Regional. Dissertação de Mestrado, Publicação G.DM-291/2017, Departamento de Engenharia Civil e Ambiental, Universidade de Brasília, Brasília, DF, 90 p.
- Rumelhart, D. E., Hinton, G. E., & McClelland, J. L. (1986). A General framework for Parallel Distributed Processing. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*.
- Sassa, K., Nagai, O., Solidum, R., Yamazaki, Y., & Ohta, H. (2010). An integrated model simulating the initiation and motion of earthquake and rain induced rapid landslides and its application to the 2006 Leyte landslide. *Landslides*, 7(3), 219–236. <http://doi.org/10.1007/s10346-010-0230-z>
- Schuster, R. L., & Highland, L. M. (2007). The third Hans Cloos lecture. Urban landslides: Socioeconomic impacts and overview of mitigative strategies. *Bulletin of Engineering Geology and the Environment*, 66(1), 1–27. <http://doi.org/10.1007/s10064-006-0080-z>
- Shroder, J. F., Ellis, J. T., & Sherman, D. J. (2015). *Hazards and Disasters Series Coastal and Marine Hazards , Risks , and Disasters*.
- Sowers, G. F. (1979). *Introductory Soil Mechanics and Foundations: Geotechnical Engineering*. (Macmillan, Ed.) (4th ed.). New York.
- Terlien, M. T. J. (1998). The determination of statistical and deterministic hydrological landslide-triggering thresholds. *Environmental Geology*, 35(2–3), 124–130. <http://doi.org/10.1007/s002540050299>
- Tromp-Van Meerveld, H. J., & McDonnell, J. J. (2006). Threshold relations in subsurface stormflow: 2. The fill and spill hypothesis. *Water Resources Research*, 42(2), 1–11. <http://doi.org/10.1029/2004WR003800>
- van Genuchten, M. T. (1980). A Closed-form Equation for Predicting the Hydraulic Conductivity of Unsaturated Soils1. *Soil Science Society of America Journal*, 44(5), 892. <http://doi.org/10.2136/sssaj1980.03615995004400050002x>
- van Westen, C. J., van Asch, T. W. J., & Soeters, R. (2006). Landslide hazard and risk zonation - Why is it still so difficult? *Bulletin of Engineering Geology and the Environment*, 65(2), 167–184.

<http://doi.org/10.1007/s10064-005-0023-0>

- Varnes, D. J. (1978). *Slope movements types and processes*. In: Schuster R.L., y Krizek R.J. (ed.). *Landslides analysis and control*. Washington D. C, National Academy Press, *Transportation Research Board Special Report, 176*, 9-33 p.
- Walker, L. R., & Shiels, A. B. (2013). Physical causes and consequences for Landslide Ecology. *Landslide Ecology*, 46–82.
- Wang, G., & Sassa, K. (2007). On the pore-pressure generation and movement of rainfall-induced landslides in laboratory flume tests. *Progress in Landslide Science*, 69, 167–181. http://doi.org/10.1007/978-3-540-70965-7_12
- Wang, Y., Shao, M., Han, X., & Liu, Z. (2015). Spatial Variability of Soil Parameters of the van Genuchten Model at a Regional Scale. *CLEAN - Soil, Air, Water*, 43(2), 271–278. <http://doi.org/10.1002/clen.201300903>
- Widrow, B., & Hoff, M. (1960). Adaptive switching circuits. *1960 IRE WESCON Convention Record*.
- Yesilnacar, E., & Topal, T. (2005). Landslide susceptibility mapping: A comparison of logistic regression and neural networks methods in a medium scale study, Hendek region (Turkey). *Engineering Geology*, 79(3–4), 251–266. <http://doi.org/10.1016/j.enggeo.2005.02.002>
- Zárate, L. E., Gonçalves, W. de B., Assis, E. S., & Dias, S. M. (2008). Estimativa De Dados Climáticos Utilizando Redes Neurais Artificiais Para Fins De Zoneamento Bioclimático Do Estado De Minas Gerais. *Entac*, (1).
- Zhou, G., Esaki, T., Mitani, Y., Xie, M., & Mori, J. (2003). Spatial probabilistic modeling of slope failure using an integrated GIS Monte Carlo simulation approach. *Engineering Geology*, 68(3–4), 373–386. [http://doi.org/10.1016/S0013-7952\(02\)00241-7](http://doi.org/10.1016/S0013-7952(02)00241-7)

ANEXO 1

PERFILES SUCCÃO VS. PROFUNDIDADE

(Poropressão nas abscissas (u) em kPa e profundidade (Zs) nas ordenadas em m)

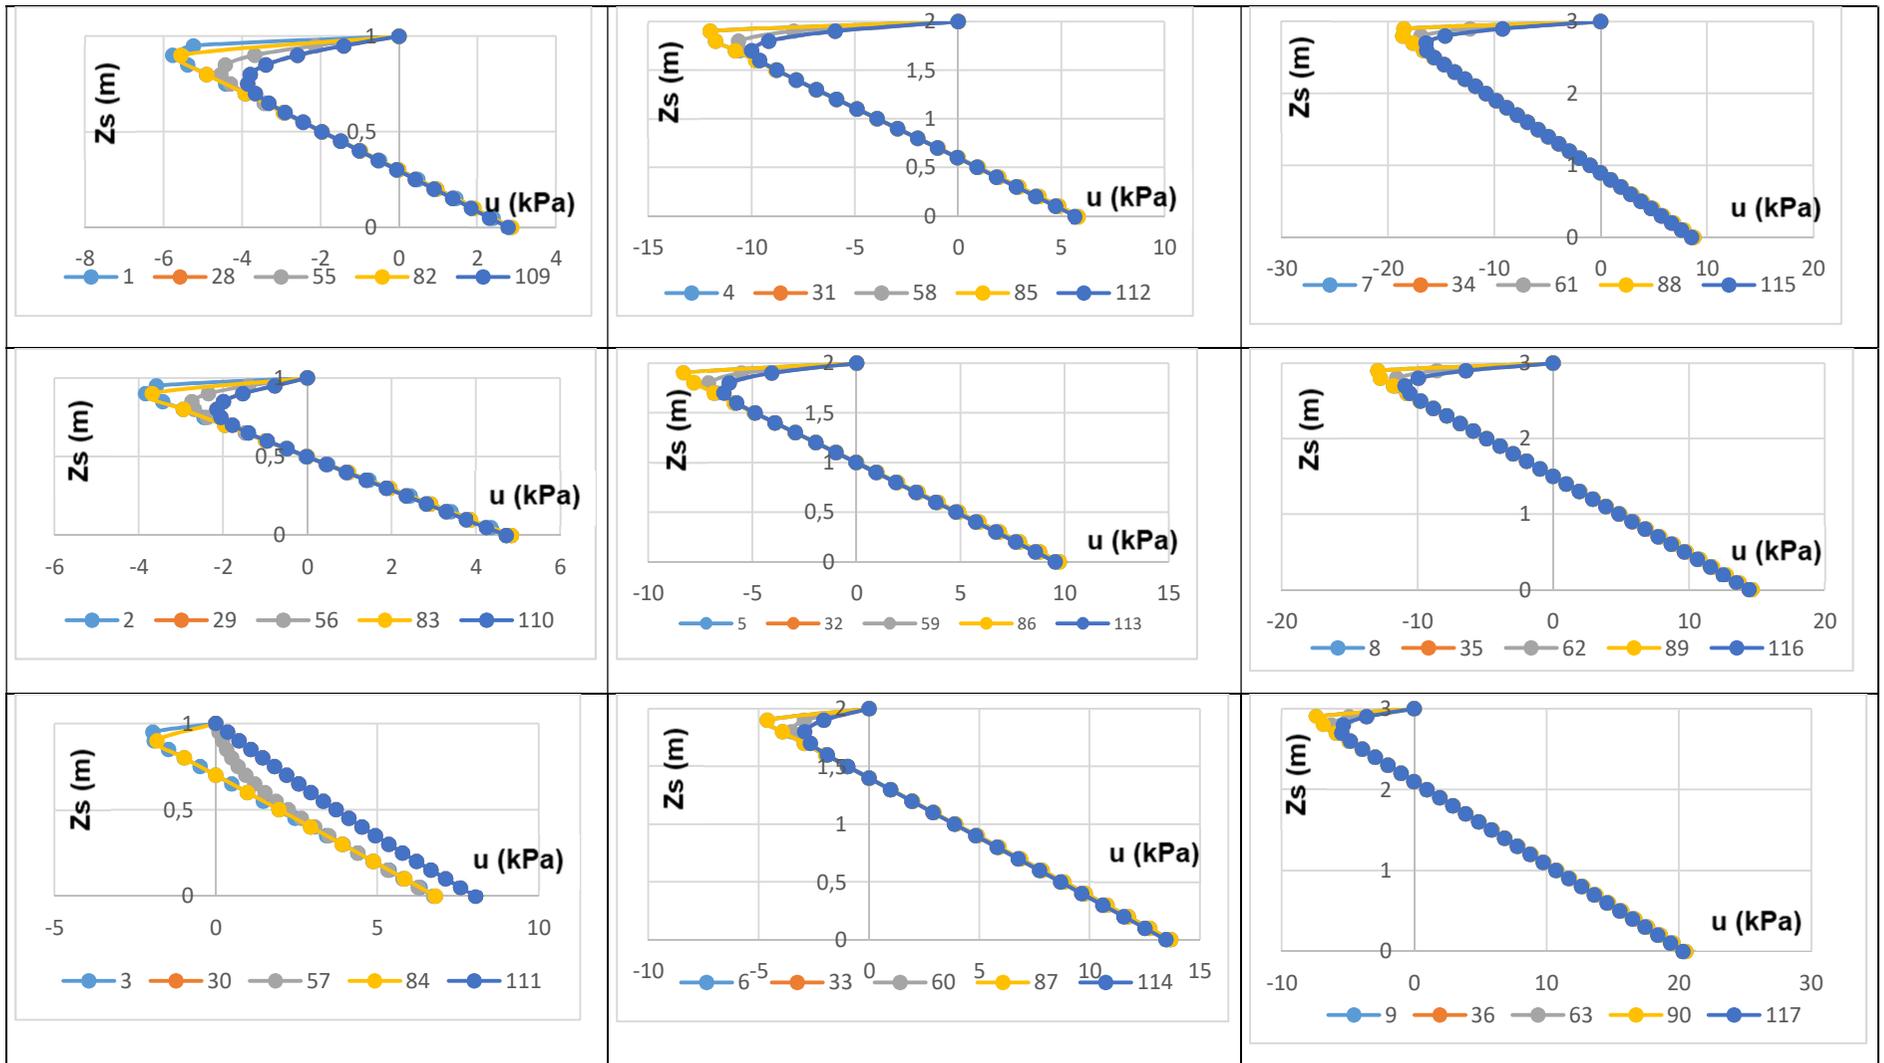
CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)	CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)
1	10	1	0,3	1	5	5	151	28	10	1	0,3	1	5	100	48
2	10	1	0,5	1	5	5	151	29	10	1	0,5	1	5	100	48
3	10	1	0,7	1	5	5	151	30	10	1	0,7	1	5	100	48
4	10	2	0,6	1	5	5	151	31	10	2	0,6	1	5	100	48
5	10	2	1	1	5	5	151	32	10	2	1	1	5	100	48
6	10	2	1,4	1	5	5	151	33	10	2	1,4	1	5	100	48
7	10	3	0,9	1	5	5	151	34	10	3	0,9	1	5	100	48
8	10	3	1,5	1	5	5	151	35	10	3	1,5	1	5	100	48
9	10	3	2,1	1	5	5	151	36	10	3	2,1	1	5	100	48
10	20	1	0,3	1	5	5	151	37	20	1	0,3	1	5	100	48
11	20	1	0,5	1	5	5	151	38	20	1	0,5	1	5	100	48
12	20	1	0,7	1	5	5	151	39	20	1	0,7	1	5	100	48
13	20	2	0,6	1	5	5	151	40	20	2	0,6	1	5	100	48
14	20	2	1	1	5	5	151	41	20	2	1	1	5	100	48
15	20	2	1,4	1	5	5	151	42	20	2	1,4	1	5	100	48
16	20	3	0,9	1	5	5	151	43	20	3	0,9	1	5	100	48
17	20	3	1,5	1	5	5	151	44	20	3	1,5	1	5	100	48
18	20	3	2,1	1	5	5	151	45	20	3	2,1	1	5	100	48
19	30	1	0,3	1	5	5	151	46	30	1	0,3	1	5	100	48
20	30	1	0,5	1	5	5	151	47	30	1	0,5	1	5	100	48
21	30	1	0,7	1	5	5	151	48	30	1	0,7	1	5	100	48
22	30	2	0,6	1	5	5	151	49	30	2	0,6	1	5	100	48
23	30	2	1	1	5	5	151	50	30	2	1	1	5	100	48
24	30	2	1,4	1	5	5	151	51	30	2	1,4	1	5	100	48
25	30	3	0,9	1	5	5	151	52	30	3	0,9	1	5	100	48
26	30	3	1,5	1	5	5	151	53	30	3	1,5	1	5	100	48
27	30	3	2,1	1	5	5	151	54	30	3	2,1	1	5	100	48

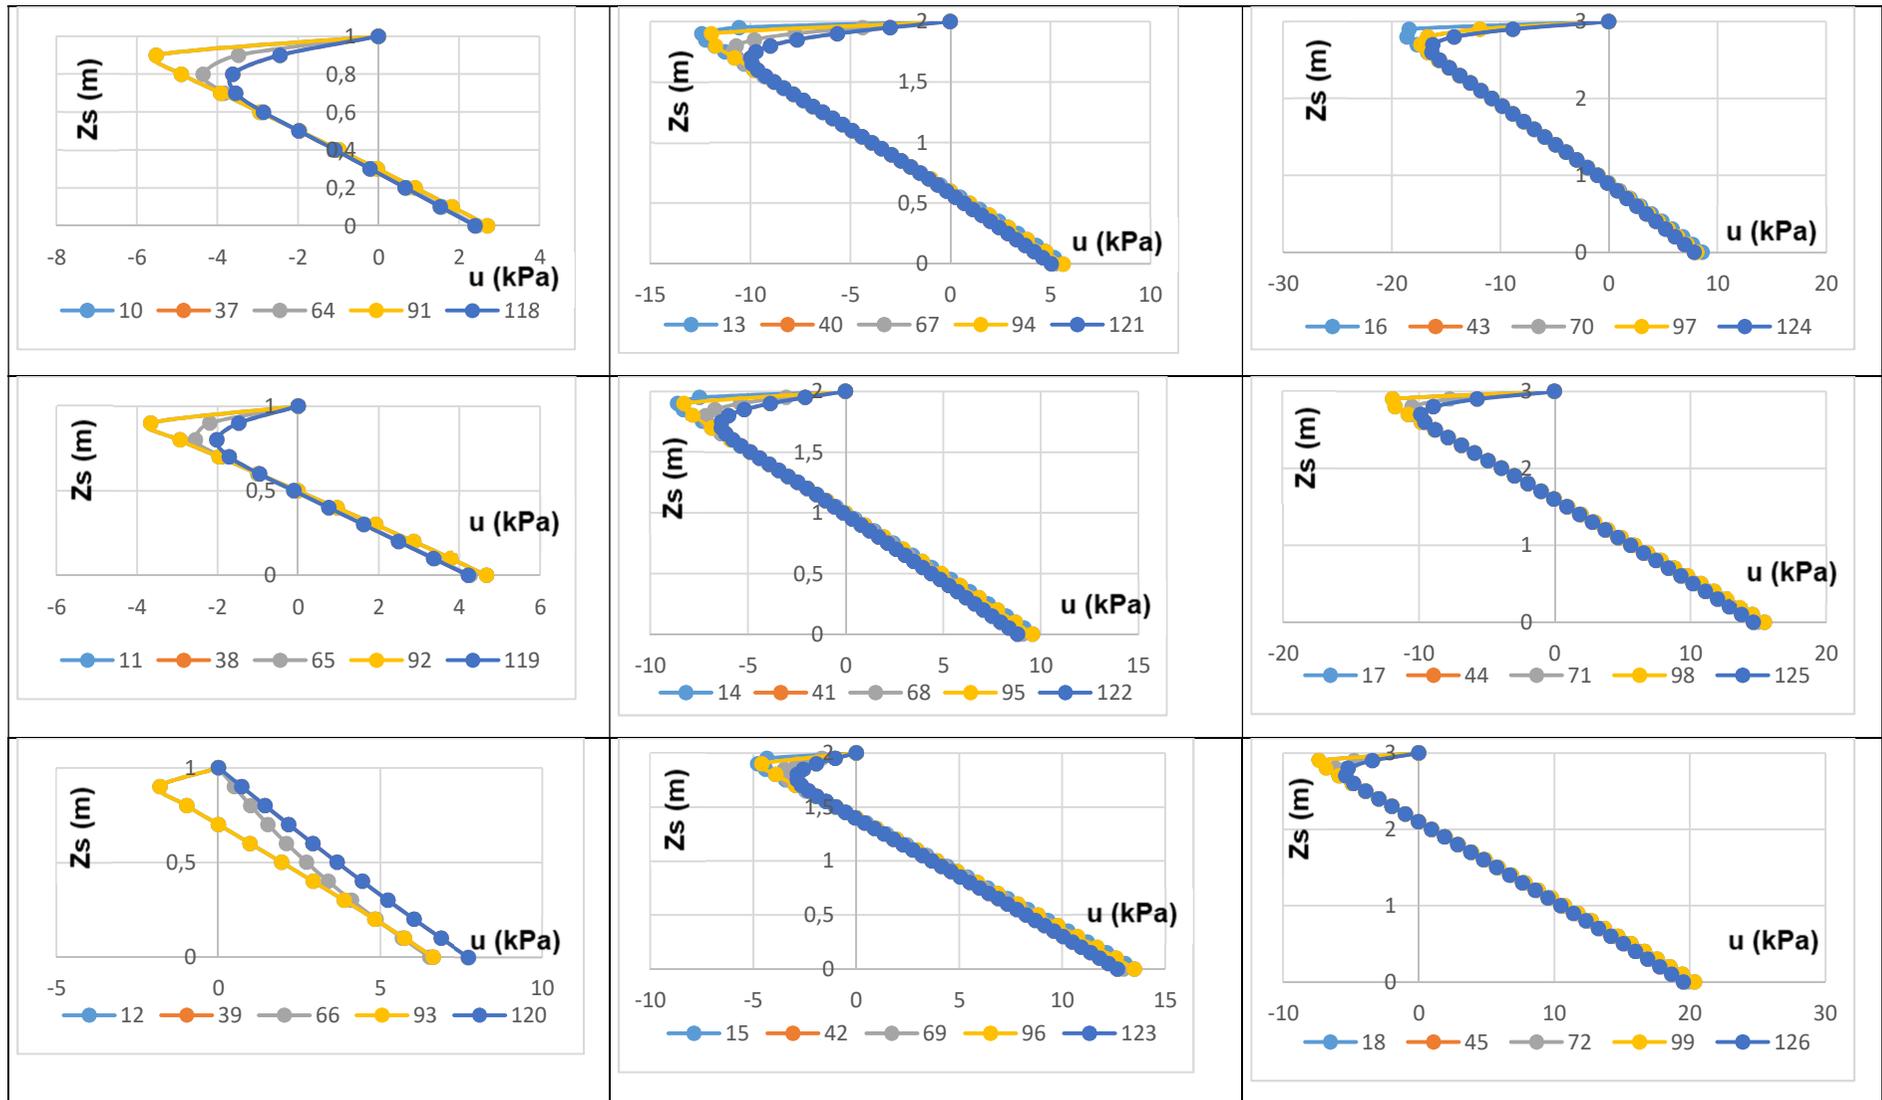
CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)	CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)
55	10	1	0,3	1	50	50	94	82	10	1	0,3	1	100	5	243
56	10	1	0,5	1	50	50	94	83	10	1	0,5	1	100	5	243
57	10	1	0,7	1	50	50	94	84	10	1	0,7	1	100	5	243
58	10	2	0,6	1	50	50	94	85	10	2	0,6	1	100	5	243
59	10	2	1	1	50	50	94	86	10	2	1	1	100	5	243
60	10	2	1,4	1	50	50	94	87	10	2	1,4	1	100	5	243
61	10	3	0,9	1	50	50	94	88	10	3	0,9	1	100	5	243
62	10	3	1,5	1	50	50	94	89	10	3	1,5	1	100	5	243
63	10	3	2,1	1	50	50	94	90	10	3	2,1	1	100	5	243
64	20	1	0,3	1	50	50	94	91	20	1	0,3	1	100	5	243
65	20	1	0,5	1	50	50	94	92	20	1	0,5	1	100	5	243
66	20	1	0,7	1	50	50	94	93	20	1	0,7	1	100	5	243
67	20	2	0,6	1	50	50	94	94	20	2	0,6	1	100	5	243
68	20	2	1	1	50	50	94	95	20	2	1	1	100	5	243
69	20	2	1,4	1	50	50	94	96	20	2	1,4	1	100	5	243
70	20	3	0,9	1	50	50	94	97	20	3	0,9	1	100	5	243
71	20	3	1,5	1	50	50	94	98	20	3	1,5	1	100	5	243
72	20	3	2,1	1	50	50	94	99	20	3	2,1	1	100	5	243
73	30	1	0,3	1	50	50	94	100	30	1	0,3	1	100	5	243
74	30	1	0,5	1	50	50	94	101	30	1	0,5	1	100	5	243
75	30	1	0,7	1	50	50	94	102	30	1	0,7	1	100	5	243
76	30	2	0,6	1	50	50	94	103	30	2	0,6	1	100	5	243
77	30	2	1	1	50	50	94	104	30	2	1	1	100	5	243
78	30	2	1,4	1	50	50	94	105	30	2	1,4	1	100	5	243
79	30	3	0,9	1	50	50	94	106	30	3	0,9	1	100	5	243
80	30	3	1,5	1	50	50	94	107	30	3	1,5	1	100	5	243
81	30	3	2,1	1	50	50	94	108	30	3	2,1	1	100	5	243

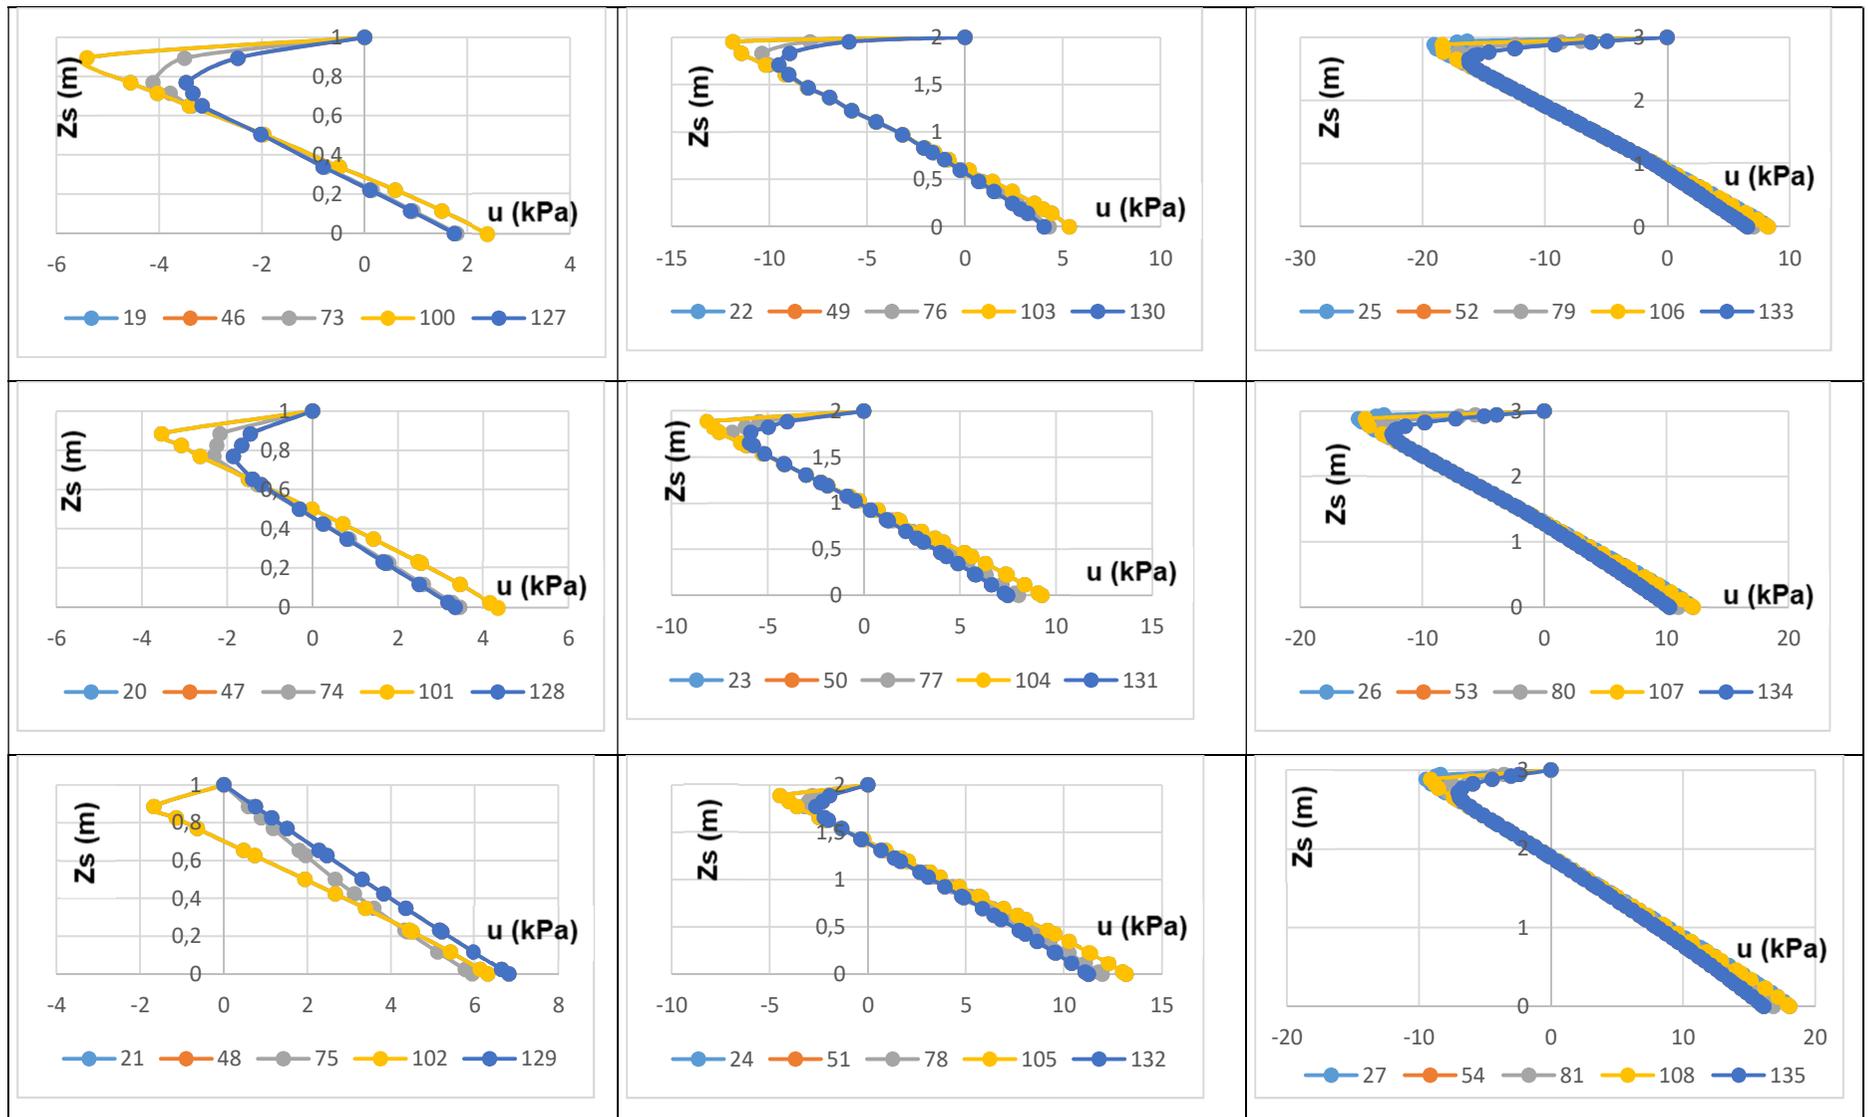
CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)	CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)
109	10	1	0,3	1	100	100	77	136	10	1	0,3	2	5	5	151
110	10	1	0,5	1	100	100	77	137	10	1	0,5	2	5	5	151
111	10	1	0,7	1	100	100	77	138	10	1	0,7	2	5	5	151
112	10	2	0,6	1	100	100	77	139	10	2	0,6	2	5	5	151
113	10	2	1	1	100	100	77	140	10	2	1	2	5	5	151
114	10	2	1,4	1	100	100	77	141	10	2	1,4	2	5	5	151
115	10	3	0,9	1	100	100	77	142	10	3	0,9	2	5	5	151
116	10	3	1,5	1	100	100	77	143	10	3	1,5	2	5	5	151
117	10	3	2,1	1	100	100	77	144	10	3	2,1	2	5	5	151
118	20	1	0,3	1	100	100	77	145	20	1	0,3	2	5	5	151
119	20	1	0,5	1	100	100	77	146	20	1	0,5	2	5	5	151
120	20	1	0,7	1	100	100	77	147	20	1	0,7	2	5	5	151
121	20	2	0,6	1	100	100	77	148	20	2	0,6	2	5	5	151
122	20	2	1	1	100	100	77	149	20	2	1	2	5	5	151
123	20	2	1,4	1	100	100	77	150	20	2	1,4	2	5	5	151
124	20	3	0,9	1	100	100	77	151	20	3	0,9	2	5	5	151
125	20	3	1,5	1	100	100	77	152	20	3	1,5	2	5	5	151
126	20	3	2,1	1	100	100	77	153	20	3	2,1	2	5	5	151
127	30	1	0,3	1	100	100	77	154	30	1	0,3	2	5	5	151
128	30	1	0,5	1	100	100	77	155	30	1	0,5	2	5	5	151
129	30	1	0,7	1	100	100	77	156	30	1	0,7	2	5	5	151
130	30	2	0,6	1	100	100	77	157	30	2	0,6	2	5	5	151
131	30	2	1	1	100	100	77	158	30	2	1	2	5	5	151
132	30	2	1,4	1	100	100	77	159	30	2	1,4	2	5	5	151
133	30	3	0,9	1	100	100	77	160	30	3	0,9	2	5	5	151
134	30	3	1,5	1	100	100	77	161	30	3	1,5	2	5	5	151
135	30	3	2,1	1	100	100	77	162	30	3	2,1	2	5	5	151

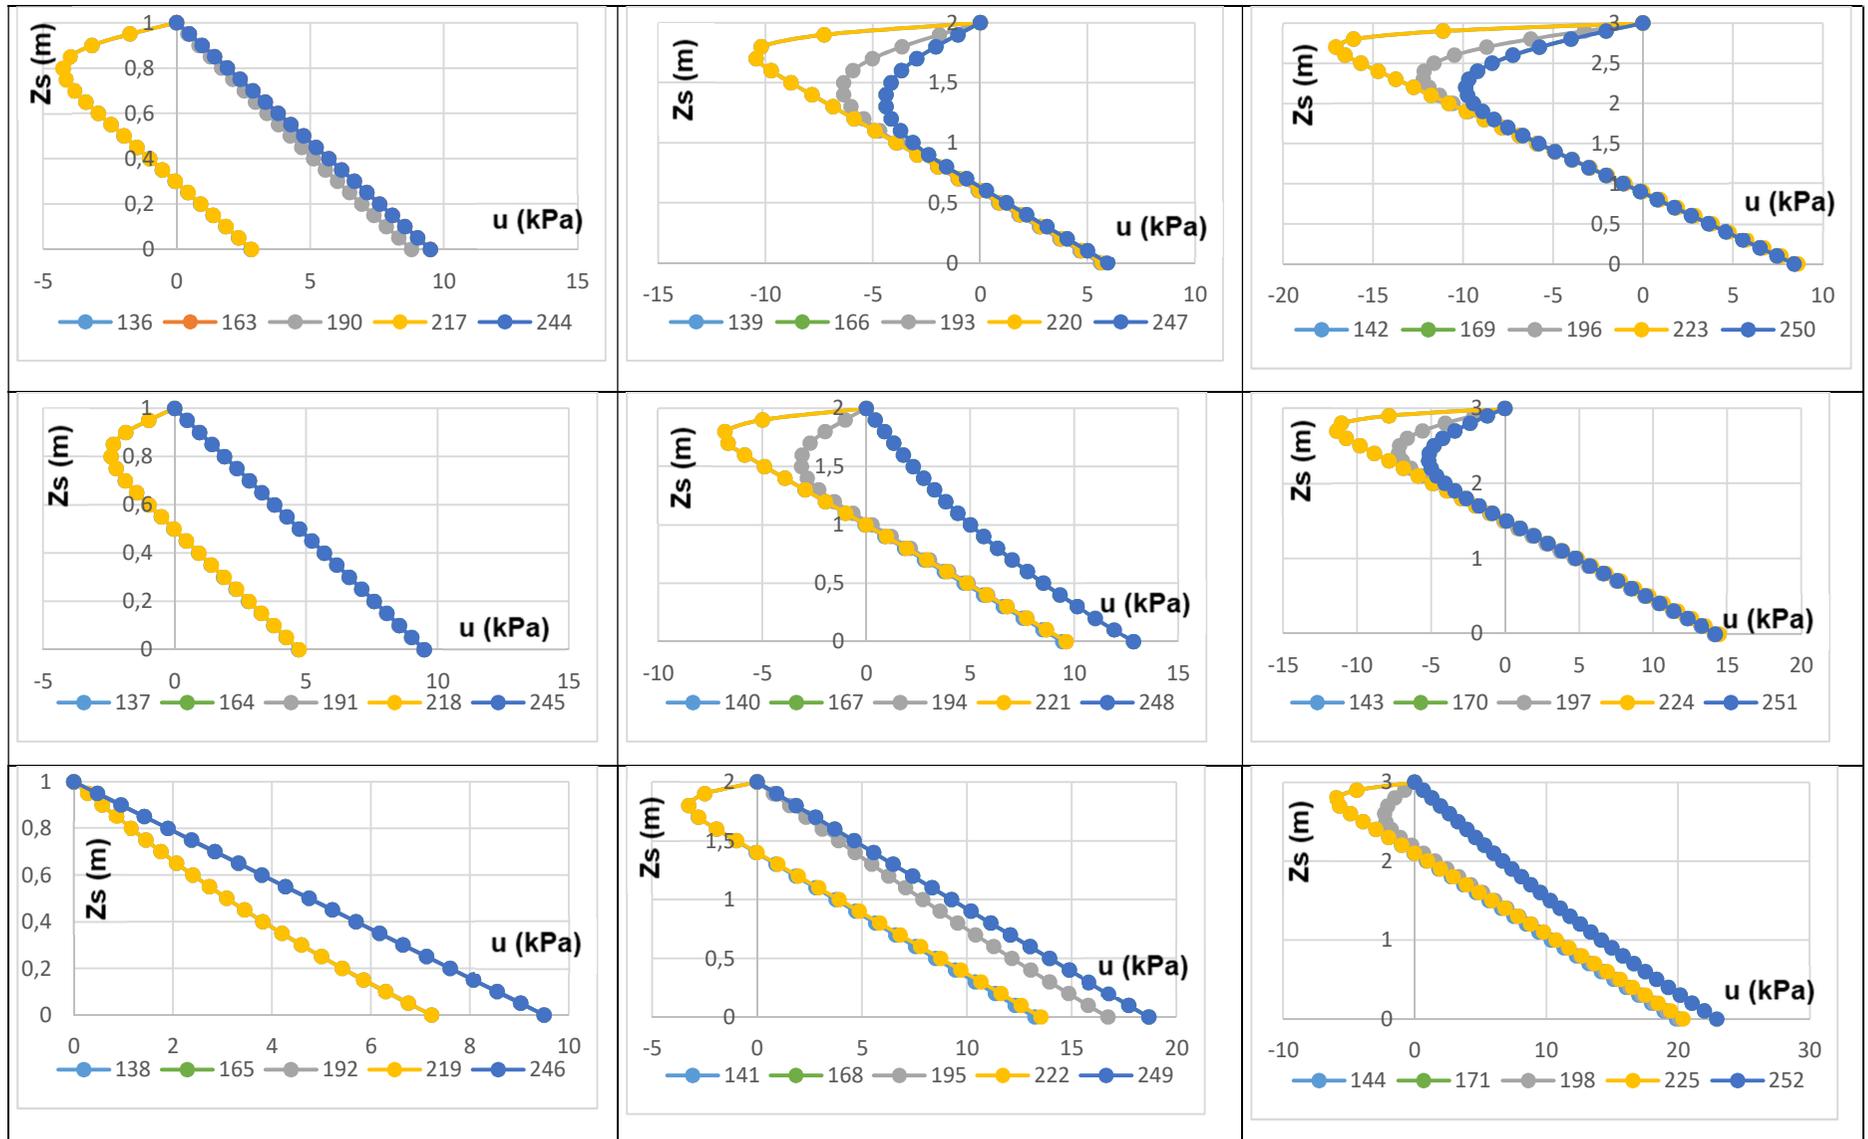
CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)	CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)
163	10	1	0,3	2	5	100	48	190	10	1	0,3	2	50	50	94
164	10	1	0,5	2	5	100	48	191	10	1	0,5	2	50	50	94
165	10	1	0,7	2	5	100	48	192	10	1	0,7	2	50	50	94
166	10	2	0,6	2	5	100	48	193	10	2	0,6	2	50	50	94
167	10	2	1	2	5	100	48	194	10	2	1	2	50	50	94
168	10	2	1,4	2	5	100	48	195	10	2	1,4	2	50	50	94
169	10	3	0,9	2	5	100	48	196	10	3	0,9	2	50	50	94
170	10	3	1,5	2	5	100	48	197	10	3	1,5	2	50	50	94
171	10	3	2,1	2	5	100	48	198	10	3	2,1	2	50	50	94
172	20	1	0,3	2	5	100	48	199	20	1	0,3	2	50	50	94
173	20	1	0,5	2	5	100	48	200	20	1	0,5	2	50	50	94
174	20	1	0,7	2	5	100	48	201	20	1	0,7	2	50	50	94
175	20	2	0,6	2	5	100	48	202	20	2	0,6	2	50	50	94
176	20	2	1	2	5	100	48	203	20	2	1	2	50	50	94
177	20	2	1,4	2	5	100	48	204	20	2	1,4	2	50	50	94
178	20	3	0,9	2	5	100	48	205	20	3	0,9	2	50	50	94
179	20	3	1,5	2	5	100	48	206	20	3	1,5	2	50	50	94
180	20	3	2,1	2	5	100	48	207	20	3	2,1	2	50	50	94
181	30	1	0,3	2	5	100	48	208	30	1	0,3	2	50	50	94
182	30	1	0,5	2	5	100	48	209	30	1	0,5	2	50	50	94
183	30	1	0,7	2	5	100	48	210	30	1	0,7	2	50	50	94
184	30	2	0,6	2	5	100	48	211	30	2	0,6	2	50	50	94
185	30	2	1	2	5	100	48	212	30	2	1	2	50	50	94
186	30	2	1,4	2	5	100	48	213	30	2	1,4	2	50	50	94
187	30	3	0,9	2	5	100	48	214	30	3	0,9	2	50	50	94
188	30	3	1,5	2	5	100	48	215	30	3	1,5	2	50	50	94
189	30	3	2,1	2	5	100	48	216	30	3	2,1	2	50	50	94

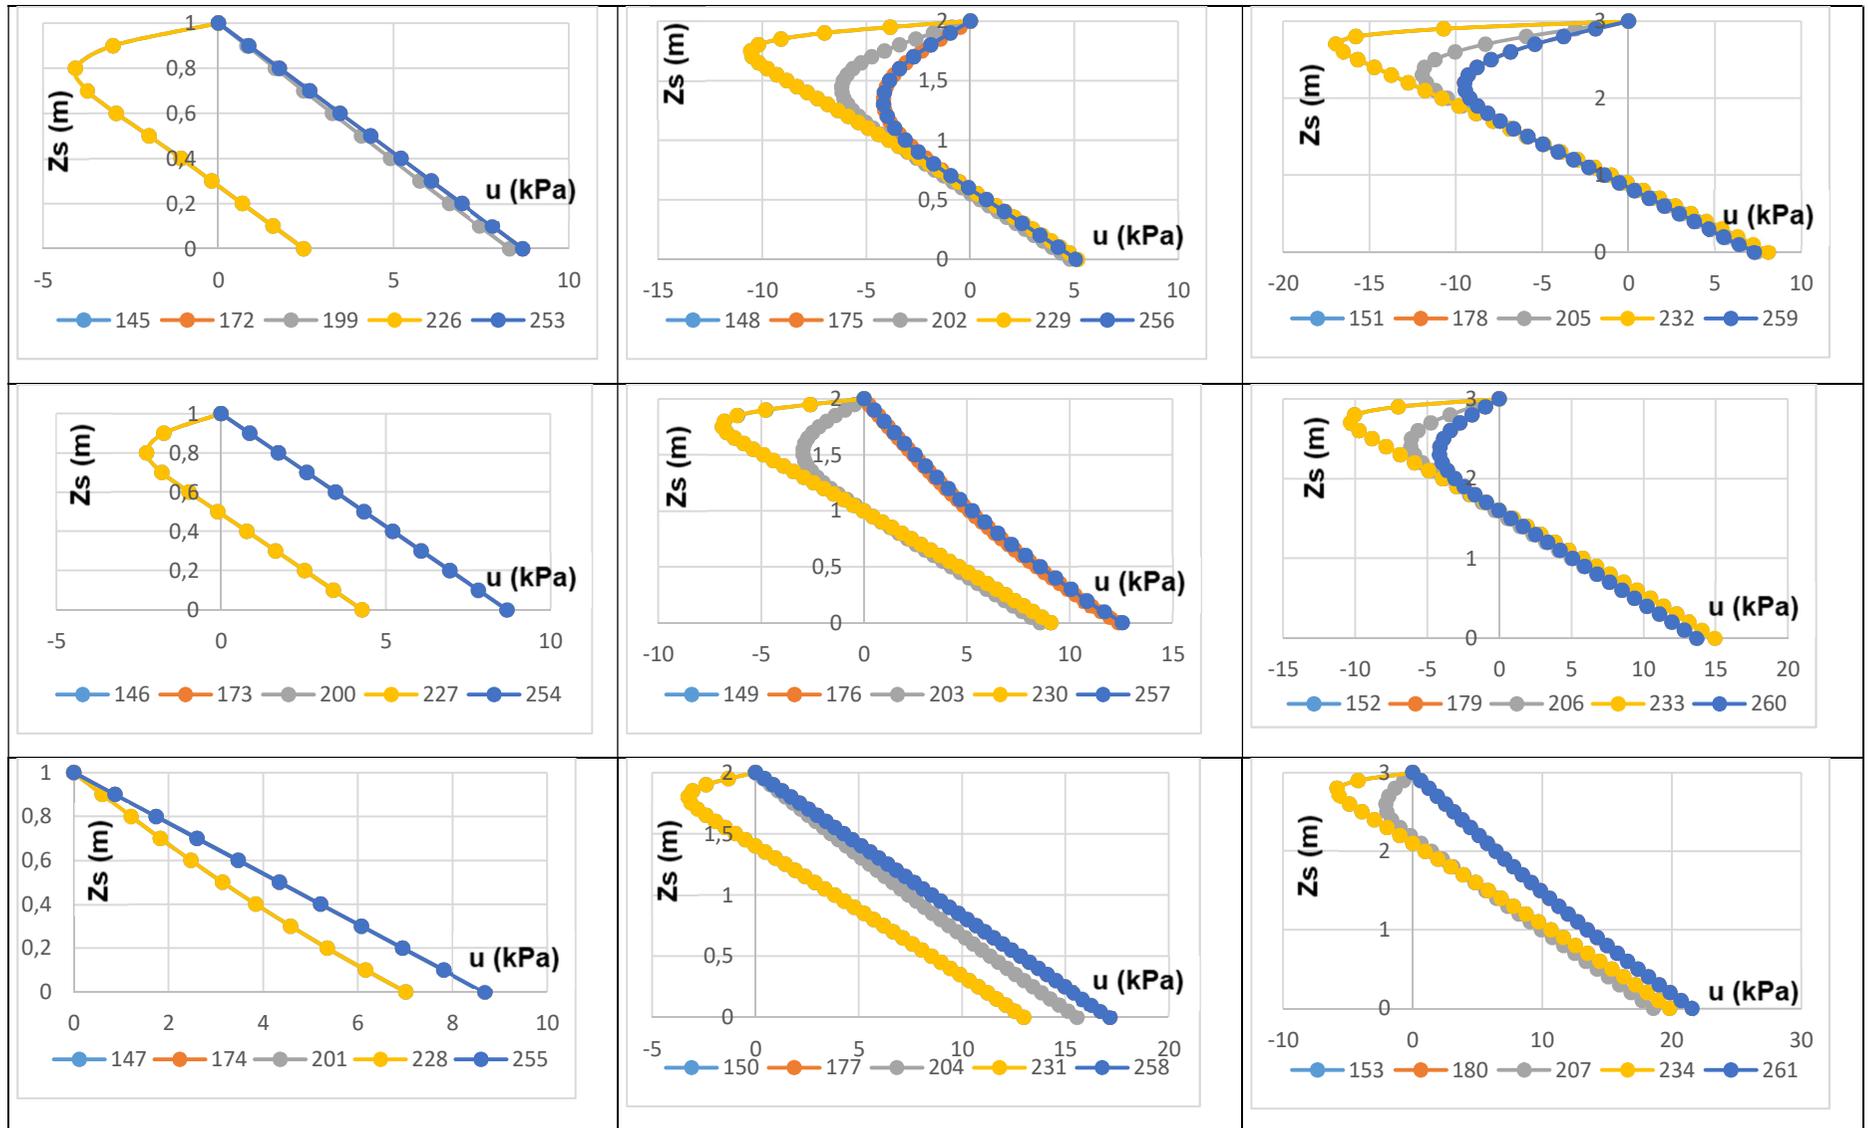
CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)	CASO	DECLIVIDADE (GRAUS)	Zs (m)	Zw (m)	solo	Tr (anos)	t (minutos)	I (mm/h)
217	10	1	0,3	2	100	5	243	244	10	1	0,3	2	100	100	77
218	10	1	0,5	2	100	5	243	245	10	1	0,5	2	100	100	77
219	10	1	0,7	2	100	5	243	246	10	1	0,7	2	100	100	77
220	10	2	0,6	2	100	5	243	247	10	2	0,6	2	100	100	77
221	10	2	1	2	100	5	243	248	10	2	1	2	100	100	77
222	10	2	1,4	2	100	5	243	249	10	2	1,4	2	100	100	77
223	10	3	0,9	2	100	5	243	250	10	3	0,9	2	100	100	77
224	10	3	1,5	2	100	5	243	251	10	3	1,5	2	100	100	77
225	10	3	2,1	2	100	5	243	252	10	3	2,1	2	100	100	77
226	20	1	0,3	2	100	5	243	253	20	1	0,3	2	100	100	77
227	20	1	0,5	2	100	5	243	254	20	1	0,5	2	100	100	77
228	20	1	0,7	2	100	5	243	255	20	1	0,7	2	100	100	77
229	20	2	0,6	2	100	5	243	256	20	2	0,6	2	100	100	77
230	20	2	1	2	100	5	243	257	20	2	1	2	100	100	77
231	20	2	1,4	2	100	5	243	258	20	2	1,4	2	100	100	77
232	20	3	0,9	2	100	5	243	259	20	3	0,9	2	100	100	77
233	20	3	1,5	2	100	5	243	260	20	3	1,5	2	100	100	77
234	20	3	2,1	2	100	5	243	261	20	3	2,1	2	100	100	77
235	30	1	0,3	2	100	5	243	262	30	1	0,3	2	100	100	77
236	30	1	0,5	2	100	5	243	263	30	1	0,5	2	100	100	77
237	30	1	0,7	2	100	5	243	264	30	1	0,7	2	100	100	77
238	30	2	0,6	2	100	5	243	265	30	2	0,6	2	100	100	77
239	30	2	1	2	100	5	243	266	30	2	1	2	100	100	77
240	30	2	1,4	2	100	5	243	267	30	2	1,4	2	100	100	77
241	30	3	0,9	2	100	5	243	268	30	3	0,9	2	100	100	77
242	30	3	1,5	2	100	5	243	269	30	3	1,5	2	100	100	77
243	30	3	2,1	2	100	5	243	270	30	3	2,1	2	100	100	77

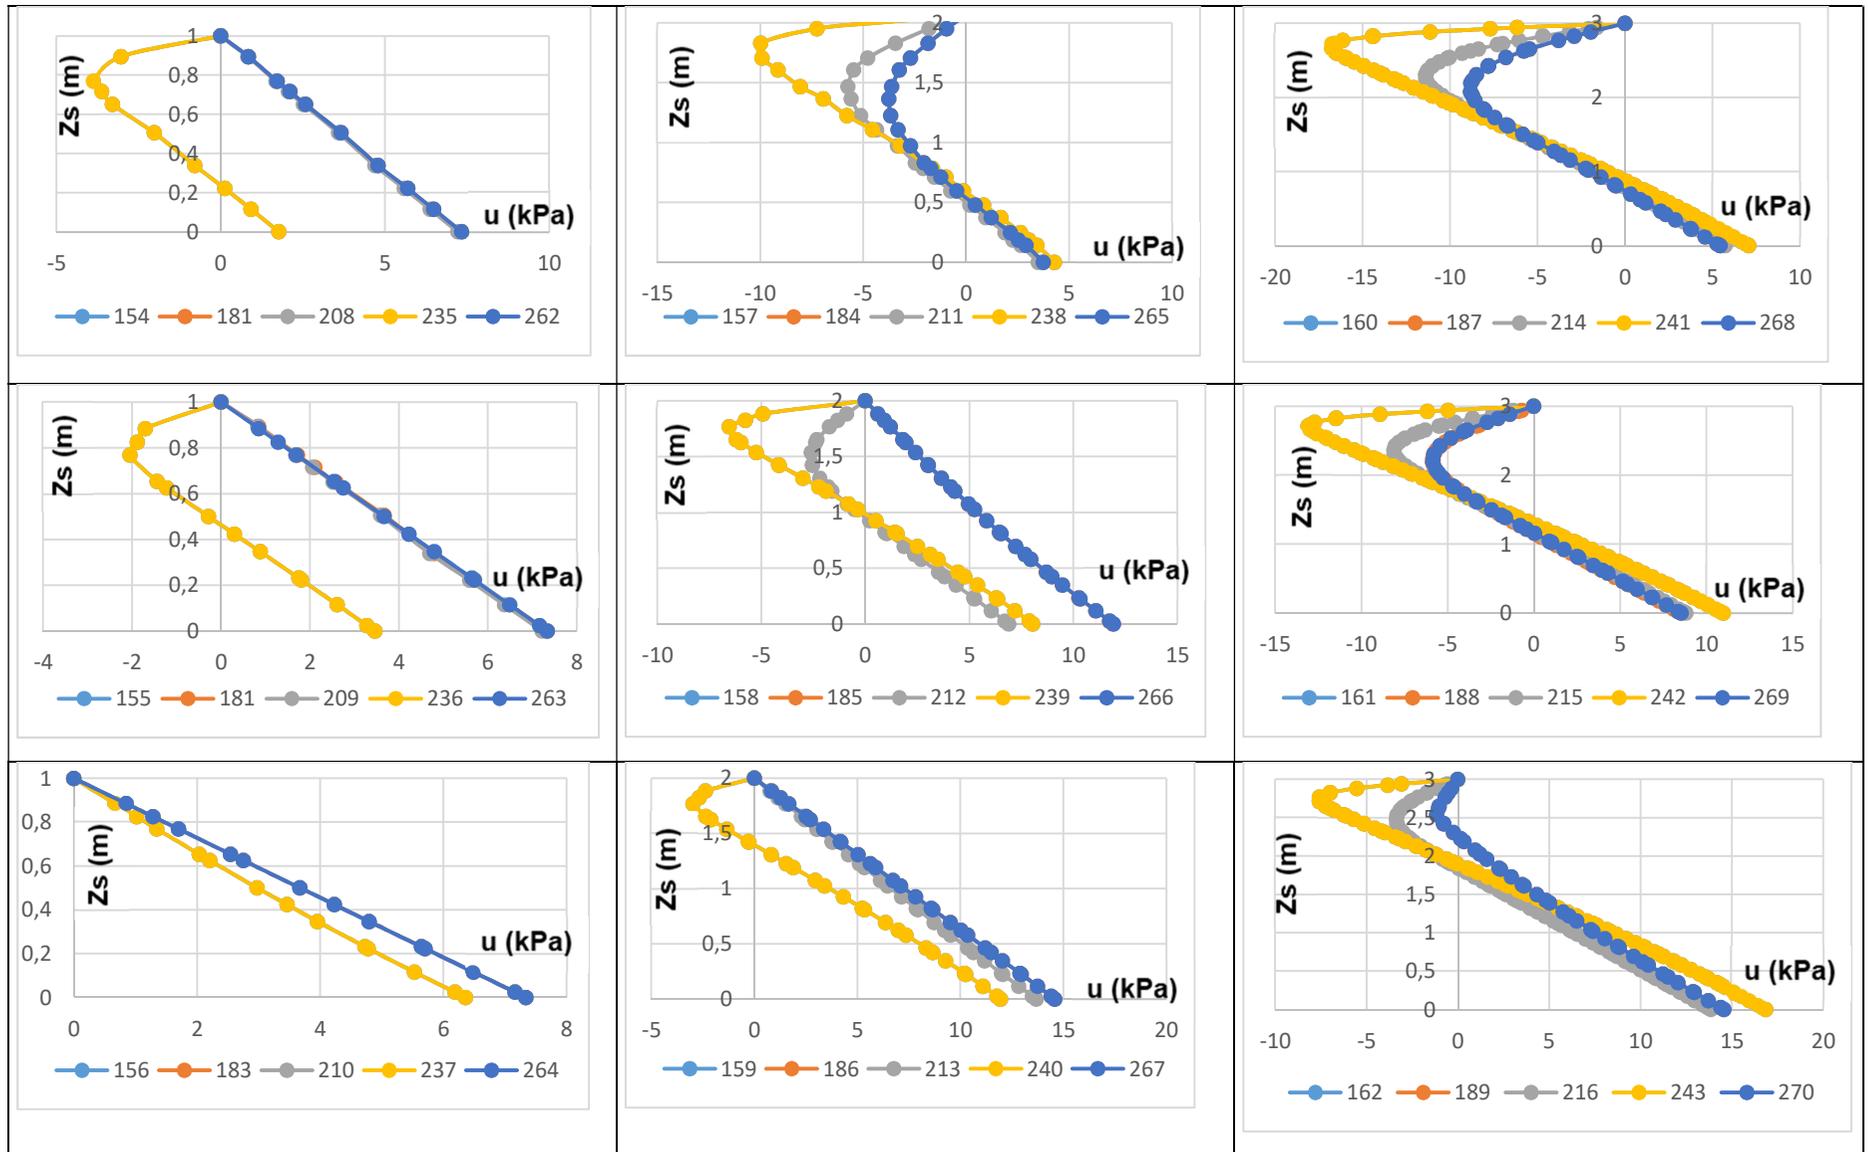












ANEXO 2
PARÂMETROS RNA

RNA ARGILAS-SILTOSAS

Pesos camada 1

0.045941	1.7392	2.0643	-1.3371	0.093277;
-0.025104	1.8553	3.0271	-0.99015	0.026821;
0.06658	0.40012	0.084663	1.0214	0.0010055;
-0.0070148	-1.3033	-2.5105	0.56719	0.00033883;
-0.040965	-0.96647	-0.037235	-1.2759	-0.026829;
-0.0052955	-1.967	2.1408	0.804	-0.011702;
-0.024766	4.17	0.095359	3.0526	-0.037279;
2.6139	1.9501	1.1654	-11.4912	-0.16811

Bias camada 1

-0.65418 -1.2145 -4.0171 -1.4495 -3.1082 0.86898 1.1555 -0.53862;
-1.868 -2.6259 -5.3937 -2.6289 -4.0151 1.3326 1.1493 -0.75479;
-0.067215 -0.10307 -3.5881 -0.32037 -3.0968 0.098868 1.2498 -0.28246;
-0.91111 -1.9124 -1.2582 -2.0311 -1.1051 0.92773 0.27783 -0.11002

Pesos camada 2

-3.0074;
0.38217;
0.16901;
0.21467;
-1.0838;
1.1545;
-3.3204;
6.7955

Bias camada 2

-1.235;
-2.1945;
-0.62167;
-0.45457

RNA AREIAS - SILTOSAS

Pesos camada 1

-0.074147 1.3118 -1.8129 -0.40308 0.1787;
-0.45614 -2.3081 1.2971 0.21483 0.16411;
-0.62793 -0.8422 -0.29051 -0.016335 0.075744;
-0.5597 -1.2458 -0.30575 0.046443 0.092811;
0.070017 1.3567 -0.34053 0.022195 0.03265;
0.13647 0.11266 -0.23856 0.14542 -0.0022551;
0.10831 0.69851 -0.63146 0.030429 0.027389;
1.346 1.8883 -1.2105 0.5559 2.0073

Bias camada 1

-0.30812 0.16928 1.6142 -1.2183 1.8298 -0.12371 -1.8406 0.037981;
-1.507 0.015058 1.1259 -0.516 0.080103 0.053818 -0.042605 -2.3508;
-0.0085398 -0.22487 0.61959 -0.94353 1.275 -1.0448 -0.20254 0.098595;
-1.8395 0.72376 0.88232 -0.79923 -0.17569 0.93078 -0.79849 -0.40484

Pesos camada 2

3.9417;
3.1816;
1.4964;
1.3128;
0.12773;
-0.37558;
-0.034968;
-6.0268

Bias camada 2

-0.80517;
-0.73714;
-0.010935;
1.1134

ANEXO 3
CÓDIGO CALCULO AMEAÇA

```

B = input('Declividade (%)= ')
Zs = input('Espessura da camada de solo (m)= ')
Zw = input('Posición inicial do lençol freatico, porcentagem de Zs (%)= ')
D = input('Duração da chuva (min)= ')
I = input('Intesidade da chuva (mm/h)= ')

Z = input('Produndidade na qual se deseja obter a poropressao (m)= ')
S = input('Tipo de solo 0: Argila 1:Areia ')

%obter dimensão das matrices
dim=size(B);
nlin=dim(1,1);
ncol=dim(1,2);
%obter vetores de entrada para uso da rede
e=[B(:)/100
   Zs(:)/3
   Zw(:)/100
   D(:)/100
   I(:)/243];
%Colocar matriz S (tipo de solo) como uma linha só
SS=S(:);
%Calcular usando a rede correspondente a cada tipo de solo
RNA=zeros(4,nlin*ncol);
for i=1:nlin*ncol
%verificar si es NODATA
% if B<0
%   RNA(:,i)=-9999
%verificar si es NODATA
if(SS(i) < 1)
RNA(:,i)=sim(N01, e(:,i));
elseif (SS(i) >= 1)
RNA(:,i)=sim(N1, e(:,i));
end

end

%RNA1:primeira linha da matriz saida da RNA
%RNA2:primeira linha da matriz saida da RNA
%RNA3:primeira linha da matriz saida da RNA
%RNA4:primeira linha da matriz saida da RNA
RNA1=reshape(RNA(1,:),[nlin, ncol]);
RNA2=reshape(RNA(2,:),[nlin, ncol]);
RNA3=reshape(RNA(3,:),[nlin, ncol]);
RNA4=reshape(RNA(4,:),[nlin, ncol]);
n=1;
for i=1:nlin
for j=1:ncol
xd(:,n)=[RNA1(i,j)
RNA2(i,j)
RNA4(i,j)];

```

```

yd(:,:,n)=[0
(Zs(i,j)*Zw(i,j))/100
RNA3(i,j)];

xu(:,:,n)=[RNA4(i,j)
0];

yu(:,:,n)=[RNA3(i,j)
Zs(i,j)];
n=n+1;
end

end

for i=1:nlin*ncol
%% Fit: 'untitled fit 1'.
[xData, yData] = prepareCurveData( yd(:,:,i), xd(:,:,i) );

% Set up fitype and options.
ft = 'linearinterp';

% Fit model to data.
[fitresult, gof] = fit( xData, yData, ft, 'Normalize', 'on' );
fa{i}= fitresult;

%% Fit: 'untitled fit 1'.
[xData1, yData1] = prepareCurveData( yu(:,:,i), xu(:,:,i));

% Set up fitype and options.
ft1 = 'linearinterp';

% Fit model to data.
[fitresult1, gof] = fit( xData1, yData1, ft1, 'Normalize', 'on' );
fa1{i}=fitresult1;
end
fa=reshape(fa,[nlin, ncol]);
fa1=reshape(fa1,[nlin, ncol]);
%% Plot fit with data.
% figure( 'Name', 'Poropressão' );
% h = plot( fitresult, xData, yData );
% hold on
% h = plot( fitresult1, xData1, yData1 );
% legend( h, 'xd vs. yd', 'untitled fit down', 'Location', 'NorthEast' );
%% Label axes
% xlabel Z(m)
% ylabel Poropressão(kPa)

```

```

% grid on

u=zeros(nlin, ncol);
for i=1:nlin
    for j=1:ncol

if (Z(i,j)<=Zw(i,j))
    u(i,j)=fa {i,j}(Z(i,j));
elseif (Z(i,j)>Zw(i,j))
    u(i,j)=fal {i,j}(Z(i,j));
end
    end
end

%CALCULO DO FATOR DE SEGURANÇA TALUDE INFINITO
FS=zeros(nlin,ncol);
for i=1:nlin
    for j=1:ncol
        FS(i,j)=(C(i,j)+((gamma(i,j)*Zs(i,j)*cos(Brad(i,j))*cos(Brad(i,j))-
            u(i,j))*tan(phirad(i,j))))/(gamma(i,j)*Zs(i,j)*cos(Brad(i,j))*sin(Brad(i,j)));
    end
end
end

```