

UNIVERSIDADE FEDERAL DE GOIÁS
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA
E DE COMPUTAÇÃO

**DISPOSITIVO PARA ENSAIO AUTOMÁTICO DE
SEDIMENTAÇÃO E ANÁLISE GRANULOMÉTRICA DO
SOLO**

Daniel Warles Pereira Martins

[UFG] & [EMC]
[Goiânia - Goiás - Brasil]
9 de janeiro de 2019

**TERMO DE CIÊNCIA E DE AUTORIZAÇÃO PARA DISPONIBILIZAR
VERSÕES ELETRÔNICAS DE TESES E DISSERTAÇÕES
NA BIBLIOTECA DIGITAL DA UFG**

Na qualidade de titular dos direitos de autor, autorizo a Universidade Federal de Goiás (UFG) a disponibilizar, gratuitamente, por meio da Biblioteca Digital de Teses e Dissertações (BDTD/UFG), regulamentada pela Resolução CEPEC nº 832/2007, sem ressarcimento dos direitos autorais, de acordo com a Lei nº 9610/98, o documento conforme permissões assinaladas abaixo, para fins de leitura, impressão e/ou *download*, a título de divulgação da produção científica brasileira, a partir desta data.

1. Identificação do material bibliográfico: Dissertação Tese

2. Identificação da Tese ou Dissertação:

Nome completo do autor: DANIEL WARLES PEREIRA MARTINS

Título do trabalho: DISPOSITIVO PARA ENSAIO AUTOMÁTICO DE
SEDIMENTAÇÃO E ANÁLISE GRANULOMÉTRICA DO SOLO

3. Informações de acesso ao documento:

Concorda com a liberação total do documento SIM NÃO¹

Havendo concordância com a disponibilização eletrônica, torna-se imprescindível o envio do(s) arquivo(s) em formato digital PDF da tese ou dissertação.


Assinatura do(a) autor(a)²

Ciente e de acordo:


Assinatura do(a) orientador(a)²

Data: 09 / 03 / 2019

¹ Neste caso o documento será embargado por até um ano a partir da data de defesa. A extensão deste prazo suscita justificativa junto à coordenação do curso. Os dados do documento não serão disponibilizados durante o período de embargo.

Casos de embargo:

- Solicitação de registro de patente;
- Submissão de artigo em revista científica;
- Publicação como capítulo de livro;
- Publicação da dissertação/tese em livro.

² A assinatura deve ser escaneada.

UNIVERSIDADE FEDERAL DE GOIÁS
PROGRAMA DE PÓS-GRADUAÇÃO EM
ENGENHARIA ELÉTRICA
E DE COMPUTAÇÃO

**DISPOSITIVO PARA ENSAIO AUTOMÁTICO DE
SEDIMENTAÇÃO E ANÁLISE GRANULOMÉTRICA DO
SOLO**

Daniel Warles Pereira Martins

Dissertação apresentada à Banca Examinadora como exigência parcial para a obtenção do título de Mestre em Engenharia Elétrica e de Computação pela Universidade Federal de Goiás (UFG), Escola de Engenharia Elétrica, Mecânica e de Computação (EMC), sob a orientação do Prof. Dr. Wesley Pacheco Calixto e coorientação da Profa. Dra. Virgínia Damin

[UFG] & [EMC]
[Goiânia - Goiás - Brasil]
9 de janeiro de 2019

Dados Internacionais de Catalogação na Publicação (CIP)
Sistemas da Bibliotecas da UFG, GO - Brasil

C331s Martins, Daniel Warles, 16/12/1990.

Dispositivo para Ensaio Automático de Sedimentação e Análise Granulométrica do Solo/ Daniel Warles Pereira Martins. – [Goiânia - Goiás - Brasil]: [UFG] & [EMC], 9 de janeiro de 2019.

CXIV, 114 f. : il.

Orientador: Wesley Pacheco Calixto - UFG
Coorientadora: Virgínia Damin - UFG

Dissertação - Universidade Federal de Goiás - UFG,
Escola de Engenharia Elétrica, Mecânica e de Computação
- EMC

Inclui bibliografia.

1.Textura do Solo 2.Ensaio de Sedimentação 3.Foto Sedimentação 4.Redes Neurais Artificiais. I. Calixto, Wesley Pacheco. Universidade Federal de Goiás. Programa de Pós-Graduação em Engenharia Elétrica e de Computação. III. Título

CDU 621.3

Copyright © 9 de janeiro de 2019 by Federal University of Goias - UFG, Brazil. No part of this publication may be reproduced, stored in a retrieval system, or transmitted in any form or by any means, electronic, mechanical, photocopying, microfilming, recording or otherwise, without written permission from the Library of UFG, with the exception of any material supplied specifically for the purpose of being entered and executed on a computer system, for exclusive use of the reader of the work.



Ata de Dissertação de Mestrado

Ata da sessão de julgamento da Dissertação de Mestrado em Engenharia Elétrica e de Computação, área de concentração Engenharia de Computação, do candidato **Daniel Warles Pereira Martins**, realizada em 14 de dezembro de 2018.

Aos quatorze dias do mês de dezembro de dois mil e dezoito, às 14:00 horas, nas dependências da Escola de Engenharia Elétrica e de Computação (EMC) da Universidade Federal de Goiás (UFG), reuniram-se os seguintes membros da Comissão Examinadora designada pela Coordenadoria do Programa de Pós-graduação em Engenharia Elétrica e de Computação: Os Doutores Wesley Pacheco Calixto - Orientador (EMC/UFG), Virgínia Damin - Coorientadora (EA-UFG), Huberto José Kliemann (SOLO-UFPR), Ricardo Fouad Rabahi (MEC-IFG), Deangelis Damasceno (QUI-IFG), José Geraldo da Silva e Marco Antônio Assfalk de Oliveira (EMC-UFG), para julgar a Dissertação de Mestrado de **Daniel Warles Pereira Martins**, intitulada "**Dispositivo para ensaio automático de sedimentação e análise granulométrica do solo**", apresentada pelo Candidato como parte dos requisitos necessários à obtenção do grau de Mestre, em conformidade com a regulamentação em vigor. O Professor Doutor Wesley Pacheco Calixto, Presidente da Comissão, abriu a sessão e apresentou o candidato que discorreu sobre seu trabalho, após o que, foi argüido pelos membros da Comissão na seguinte ordem: Humberto José Kliemann, Ricardo Fouad Rabahi, Deangelis Damasceno, José Geraldo da Silva e Marco Antônio Assfalk de Oliveira. A parte pública da sessão foi então encerrada e a Comissão Examinadora reuniu-se em sessão reservada para deliberar. A Comissão julgou então que o candidato, tendo demonstrado conhecimento suficiente, capacidade de sistematização e argumentação sobre o tema de sua Dissertação, foi considerado **aprovado** e deve satisfazer as exigências listadas na Folha de Modificação de Dissertação de Mestrado, em anexo a esta Ata, no prazo máximo de 30 dias, ficando o professor orientador responsável por atestar o cumprimento dessas exigências. Os membros da Comissão Examinadora descreveram as justificativas para tal avaliação em suas respectivas Folhas de Avaliação, anexas a esta Ata. Nada mais havendo a tratar, o presidente da Comissão declarou encerrada a sessão. Nos termos do Regulamento Geral dos Cursos de Pós-graduação desta Universidade, a presente Ata foi lavrada, lida e, julgada conforme, segue assinada pelos membros da Comissão supracitados e pelo candidato. Goiânia, 14 de dezembro de 2018.

Comissão Examinadora Designada:

Wesley Pacheco Calixto - Orientador (EMC/UFG)

(Avaliação: Aprovado)

Virgínia Damin - Coorientadora (EA-UFG)

(Avaliação: Aprovado)

Deangelis Damasceno - (QUI/IFG)

(Avaliação: Aprovado)

Huberto José Kliemann - (SOLO-UFPR)

(Avaliação: Aprovado)

José Geraldo da Silva - (EMBRAPA)

(Avaliação: Aprovado)

Ricardo Fouad Rabahi - (MEC/IFG)

(Avaliação: APROVADO)

Marco Antônio Assfalk de Oliveira - (EMC/UFG)

(Avaliação: APROVADO)

Candidato:

Daniel Warles Pereira Martins
Daniel Warles Pereira Martins

*O esforço é grande e o homem é pequeno.
Eu, Diogo Cão, navegador, deixei
Este padrão ao pé do areal moreno
E para diante naveguei.*

*A alma é divina e a obra é imperfeita.
Este padrão sinala ao vento e aos céus
Que, da obra ousada, é minha a parte feita:
O por-fazer é só com Deus.*

*E ao imenso e possível oceano
Ensinam estas Quinas, que aqui vês,
Que o mar com fim será grego ou romano:
O mar sem fim é português.*

*E a Cruz ao alto diz que o que me há na alma
E faz a febre em mim de navegar
Só encontrará de Deus na eterna calma
O porto sempre por achar.*

FERNANDO PESSOA

*A todos meus benquistos familiares que abdicaram da minha
presença em vários momentos. A eles dedico este nosso trabalho.*

AGRADECIMENTOS

Agradeço a Deus pela concepção da minha existência, pelo caminho iluminado e pela paz emanada das paisagens naturais, obras de suas mãos. Agradeço a minha esposa Kassia Martins, que com amor me ajudou a superar as dificuldades dessa jornada. Agradeço a meus pais, Lusimar Pereira e Rosirley Martins, pois com muita dignidade e simplicidade me ensinaram o caminho da verdade e justiça. Agradeço a meu irmão Dayvid Wesley, pelo companheirismo e disposição. Agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), que forneceu auxílio financeiro na forma de bolsa de estudos. Agradeço a professora Virgínia Damin pela grata e essencial contribuição no desenvolvimento deste trabalho. Agradeço ao professor Márcio Rodrigues da Cunha Reis, real incentivador dos meus estudos de pós graduação. Agradeço ao professor Wanderson Rainer H. Araújo, maior contribuidor dos meus conhecimentos adquiridos durante o curso de graduação em engenharia elétrica. Em especial, agradeço ao orientador deste trabalho, professor Wesley Pacheco Calixto, que com serenidade e perspicácia iluminou meus primeiros passos como pesquisador.

RESUMO

Este trabalho apresenta dispositivo e método para reconhecimento de propriedades físico-química do solo. O dispositivo proposto, mensura o comportamento das partículas em sedimentação utilizando o princípio da foto sedimentação em multipontos. Para cada solo submetido ao ensaio no dispositivo, é gerada matriz que corresponde ao comportamento do solo. Esta matriz é submetida ao reconhecimento de padrões utilizando rede neural artificial, que identifica o tipo de solo e por associação no banco de dados, apresenta a classificação mais indicada para o solo ensaiado. Os resultados apresentados demonstram que as medidas realizadas nos multipontos fornecem informação significativa do comportamento do solo em sedimentação.

DEVICE FOR AUTOMATIC SEDIMENTATION AND SOIL PARTICLE SIZE ANALYSIS

ABSTRACT

This work presents a device and method for the recognition of soil physicochemical properties. The proposed device measures the behavior of the particles in sedimentation using the principle of photo sedimentation in multipoints. For each soil submitted to the test in the device, a matrix is generated that corresponds to the behavior of the soil. This matrix is submitted to pattern recognition using artificial neural network, which identifies the soil type and by association in the database, presents the best classification for the soil tested. The results show that the measurements carried out in the multipoints provide significant information on soil sedimentation behavior.

SUMÁRIO

Pág.

LISTA DE FIGURAS

LISTA DE TABELAS

LISTA DE SÍMBOLOS

LISTA DE ABREVIATURAS E SIGLAS

CAPÍTULO 1 INTRODUÇÃO	27
CAPÍTULO 2 CLASSIFICAÇÃO E CARACTERÍSTICA DO SOLO	33
2.1 Formação do solo	33
2.1.1 Horizontes pedogenéticos e componentes do solo	34
2.2 Taxonomia do solo	36
2.3 Características morfológicas	38
2.3.1 Cor do solo	38
2.3.2 Textura do solo	39
2.3.2.1 Areia	40
2.3.2.2 Silte	41
2.3.2.3 Argila	41
2.3.2.4 Classes texturais do solo	42
2.3.3 Estrutura do solo	42
2.4 Análise granulométrica do solo por sedimentação	43
2.5 Considerações finais	46
CAPÍTULO 3 METODOLOGIA PARA RECONHECIMENTO DE PADRÃO	49
3.1 Reconhecimento de padrões	49
3.2 Neurônio artificial	50
3.3 Rede neural artificial Perceptrons de múltiplas camadas	52
3.3.1 Algoritmo genético	56
3.3.2 Análise de sensibilidade na projeção de variáveis	59
3.4 Considerações finais	62

CAPÍTULO 4 METODOLOGIA	63
4.1 Projeto do dispositivo proposto	63
4.1.1 Projeto mecânico	64
4.1.2 Projeto eletrônico	66
4.2 Procedimento de utilização do dispositivo e construção do banco de dados	68
4.3 Rede neural artificial aplicada à reconhecimento de padrões	71
4.4 Validação do dispositivo e sistema de reconhecimento de padrões	74
4.4.1 Análise de sensibilidade na projeção de variáveis	75
4.5 Considerações finais	75
CAPÍTULO 5 RESULTADOS	77
5.1 Desenvolvimento do dispositivo	77
5.1.1 Projeto mecânico	77
5.1.2 Projeto eletrônico	78
5.2 Preparação e geração do banco de dados	80
5.2.1 Gleissolo Melânico Distrófico	82
5.2.2 Latossolo Vermelho Ácrico	84
5.2.3 Latossolo Vermelho Amarelo Distrófico Petroplíntico	86
5.2.4 Latossolo Vermelho Distrófico	87
5.2.5 Luvissole Háplico	89
5.2.6 Neossolo Flúvico Ta Distrófico	90
5.2.7 Neossolo Quartzarênico Órtico	92
5.3 Aplicação do reconhecimento de padrões	93
5.4 Testes com solos não caracterizados	97
5.5 Análise de sensibilidade na projeção de variáveis	99
5.6 Comentários	100
CAPÍTULO 6 CONCLUSÃO	105
6.1 Contribuições do Trabalho	105
6.2 Sugestões para Trabalhos Futuros	106
REFERÊNCIAS BIBLIOGRÁFICAS	107

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Hipotético perfil de solo.	35
2.2 Proporção de componentes e as fases do solo.	36
2.3 Diagrama esquemático das relações entre matriz, valor e croma.	39
2.4 Classificação do tamanho das partículas de solo.	40
2.5 Relação tamanho das partículas \times tipos de minerais presentes.	40
2.6 Triângulo textural e representações das frações granulométricas.	42
2.7 Microscopia eletrônica de partículas do solo.	43
2.8 Macroestrutura do solo e sua formação.	44
2.9 Ilustração do ensaio de sedimentação.	45
2.10 Ilustração do processo de foto sedimentação.	46
2.11 Ilustração do sinal produzido por partícula esférica na foto sedimentação.	47
3.1 Ilustração da classificação por reconhecimento de padrões biológicos.	50
3.2 Neurônio artificial.	51
3.3 Ilustração de rede Perceptron multicamadas: (a) topologia ou geometria da rede multicamadas e (b) ciclo de n iterações.	53
3.4 Ilustração hipotética de generalização adequada.	55
3.5 Ilustração do método de validação cruzada.	56
3.6 Estrutura do algoritmo genético clássico.	58
3.7 Arranjo dos dados no mínimos quadrados parciais para regressão.	60
4.1 Elementos que compõem o dispositivo proposto.	64
4.2 Projeto mecânico do dispositivo proposto: (a) câmara de retenção, (b) câmara de sedimentação e (c) vista completa.	65
4.3 Projeto mecânico do dispositivo proposto: (a) sistema emissor e receptor de luz e (b) compartimento de isolamento luminosa.	65
4.4 Projeto mecânico do dispositivo proposto: (a) configuração sem dispersão de partículas, (b) configuração com dispersão de partículas e (c) vista explodida.	66
4.5 Projeto eletrônico do dispositivo proposto: (a) sistema emissor, (b) sistema receptor, (c) sistema de controle e aquisição de dados e (d) circuito eletrônico para acionamento da válvula proporcional e motor.	67
4.6 Dispositivo proposto: (a) ilustração das partículas do solo sendo liberadas para sedimentação e (b) ilustração do feixe de luz monocromático incidindo sobre a superfície do fotodiodo.	69

4.7	Construção do banco de dados.	70
4.8	Ilustração da rede neural artificial proposta.	72
4.9	Validação cruzada onde a matriz $\mathbf{M}_{\sigma(v \times z \times k)}$ é dividida aleatoriamente em $\mathbf{A}_{1(v \times z \times k)}$, $\mathbf{A}_{2(v \times z \times k)}$ e $\mathbf{B}_{(v \times z \times k)}$	72
4.10	Algoritmo genético aplicado na topologia da rede neural artificial proposta.	73
4.11	Identificação de novas amostras.	74
5.1	Dispositivo proposto na configuração: (a) com dispersão de partículas e (b) sem dispersão de partículas.	78
5.2	Projeto eletrônico do dispositivo desenvolvido: (a) sistema emissor, (b) sistema receptor, (c) sistema de controle e aquisição de dados e (d) circuito eletrônico para acionamento da válvula proporcional e motor.	79
5.3	Sistemas emissor e receptor: (a) vista superior, (b) vista inferior, (c) laser de $5mW$ e (d) fotodiodo BPW34.	80
5.4	Sensibilidade espectral relativa \times comprimento de onda.	80
5.5	Dispositivos utilizados: (a) válvula esférica motorizada e (b) motor de corrente contínua.	80
5.6	Tensão produzida sem e com aplicação de filtro digital.	83
5.7	Gleissolo Melânico Distrófico.	83
5.8	Tensão produzida para cinco ensaios com amostras do Gleissolo Melânico Distrófico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	84
5.9	Latossolo Vermelho Ácrico.	85
5.10	Tensão produzida para cinco ensaios com amostras do Latossolo Vermelho Ácrico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	85
5.11	Latossolo Vermelho Amarelo Distrófico Petrolíntico.	86
5.12	Tensão produzida para cinco ensaios com amostras do Latossolo Vermelho Amarelo Distrófico Petrolíntico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	87
5.13	Latossolo Vermelho Distrófico.	88
5.14	Tensão produzida para cinco ensaios com amostras do Latossolo Vermelho Distrófico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	88
5.15	Luvissolo Háptico.	89
5.16	Tensão produzida para cinco ensaios com amostras do Luvissolo Háptico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	90

5.17	Neossolo Flúvico Ta Distrófico.	91
5.18	Tensão produzida para cinco ensaios com amostras do Neossolo Flúvico Ta Distrófico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	91
5.19	Neossolo Quartzarênico Órtico.	92
5.20	Tensão produzida para cinco ensaios com amostras do Neossolo Quartzarênico Órtico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	93
5.21	Evolução do algoritmo genético para os quatro primeiros indivíduos de cada geração.	95
5.22	Validação Cruzada do treinamento da MLP.	96
5.23	Solo não caracterizado.	97
5.24	Tensão produzida para quatro ensaios utilizando mistura de solo com amostras não caracterizadas no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	98
5.25	Comparação da tensão produzida para o solo $k = 7$ e para o quarto ensaio com amostra de solo não caracterizado no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	99
5.26	Comparação da tensão produzida para o solo $k = 2$ e para o primeiro ensaio com amostra de solo não caracterizado no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$	100
5.27	Curvas de tensão produzidas pelo fotodiodo $v = 1$ para todos os solos da Tabela 5.2.	102
5.28	Curvas de tensão produzidas pelo fotodiodo $v = 16$ para todos os solos da Tabela 5.2.	102
5.29	Curvas de tensão produzidas pelo fotodiodo $v = 32$ para todos os solos da Tabela 5.2.	103
5.30	Ilustração didática dos resultados da Tabela 5.14.	104

LISTA DE TABELAS

	<u>Pág.</u>
2.1 Solos do Brasil.	37
2.2 Taxonomia do Latossolo.	37
5.1 Principais medidas dos componentes do dispositivo.	77
5.2 Classificação, textura e matéria orgânica dos solos utilizados.	81
5.3 Desvio entre os ensaios para o Gleissolo Melânico Distrófico.	84
5.4 Desvio entre os ensaios para o Latossolo Vermelho Ácrico.	86
5.5 Desvio entre os ensaios para o Latossolo Vermelho Amarelo Distrófico Petroplúntico.	87
5.6 Desvio entre os ensaios para o Latossolo Vermelho Distrófico.	89
5.7 Desvio entre os ensaios para o Luvisolo Háptico.	90
5.8 Desvio entre o primeiro ensaio comparado com os demais para o Neossolo Flúvico Ta Distrófico.	92
5.9 Desvio entre os ensaios para o Neossolo Quartzarênico Órtico.	93
5.10 Topologias encontradas pelo algoritmo genético.	94
5.11 Treinamento da rede neural artificial.	96
5.12 Validação da rede neural artificial.	97
5.13 Reconhecimento das amostras não caracterizadas.	100
5.14 Importância das variáveis de projeção para cada fotodiodo.	101
5.15 Aplicação dos fotodiodos da <i>Visby</i>	101

LISTA DE SÍMBOLOS

β_{GA}	– Grau de dependência do número de gerações
γ_f	– Densidade específica do fluido
γ_p	– Densidade específica da partícula
δ	– Gradiente local
ζ	– Número de variáveis em \mathbf{X}_{MQPR}
η_{GA}	– Variável probabilística binária de decisão
μ	– Viscosidade dinâmica do fluido
ϱ	– Ordem do filtro passas-baixas Butterworth
τ	– Turbidez
τ_{GA}	– Quantidade de indivíduos competidores
φ	– Quantidade de multiplexadores
ξ	– Novas componentes ortogonais
ω	– Frequência angular do sinal em radianos por segundo
ω_c	– Frequência de corte
a_{GA}	– Gene
A	– Conjunto de treinamento
A₁	– Subconjunto de estimação
A₂	– Subconjunto de validação
b	– Limiar de ativação
b_{GA}	– Gene
B	– Conjunto de teste
B_{MQPR}	– Matriz dos coeficientes de regressão
B_1	– Saída digital do microcontrolador
B_2	– Saída digital do microcontrolador
c	– Clima
c_{GA_m}	– Cromossomo codificado
C_{MQPR}	– Matriz de pesos
C_v	– Canais de saída dos multiplexadores
d_L	– Diâmetro do feixe de luz monocromático
D	– Diâmetro da esfera da partícula dada em metros
D_{ψ_b}	– Canais para acionamento digital da multiplexação do sistema emissor
E_{ψ_b}	– Canais para acionamento digital da multiplexação do sistema receptor
F_{MQPR}	– Matriz de erro
FT_{ψ_a}	– Conexões entre o microcontrolador e multiplexador
$g(u)$	– Função de ativação
g_{GA}	– Número de geração
G	– Derivada da função de ativação
G_{BW}	– Ganho do filtro passas-baixas Butterworth
G_{MQPR}	– Matriz de erro

h_{GA}	–	Valores inteiros aleatórios
i	–	Neurônio a esquerda
I	–	Intensidades transmitidas
IN_{ψ}	–	Canal de conexão entre SCAD e multiplexadores do sistema emissor
I_0	–	Intensidades incidentes
j	–	Neurônio a direita
k	–	Quantidade de solos caracterizados
k_{GA}	–	Quantidade de simulações do algoritmo genético
K	–	Solo caracterizado
l	–	Contador de camadas intermediárias
L	–	Quantidade de neurônios na saída da MLP
L_b	–	Comprimento do caminho óptico
$LS_{\psi\alpha}$	–	Conexões entre o microcontrolador e multiplexador
m	–	Quantidade de neurônios nas camadas da MLP
$m_{F\sigma}$	–	Elementos da matriz $M_{F\sigma}$
m_{GA}	–	Quantidade de indivíduos da população
m_{MQPR}	–	Número de variáveis em \mathbf{Y}_{MQPR}
$\tilde{m}_{F\sigma}$	–	Elementos da matriz $M_{F\sigma}$ normalizada
M_{σ}	–	Matriz fornecida pelo dispositivo
ME	–	Resposta desejada para MLP
$M_{F\sigma}$	–	Matriz fornecida pelo dispositivo com sinais filtrados
$\tilde{M}_{F\sigma}$	–	Matriz fornecida pelo dispositivo com sinais filtrados e normalizada
n	–	Ciclos (épocas)
n_{GA}	–	Quantidade de genes
n_{MQPR}	–	Quantidade de observações
N	–	Última camada intermediária
o	–	Biótico
OUT_{ψ}	–	Canal de conexão entre SCAD e multiplexadores do sistema receptor
\mathbf{P}_{GA}	–	População de indivíduos
p	–	Material de origem
\mathbf{P}_{MQPR}	–	Matriz de pesos
q	–	Quantidade de linhas do vetor binário
r	–	Topografia
r_{GA}	–	número aleatório no intervalo $(0 : 1]$
S	–	Neurônios da camada de saída
S_R	–	Solo resultante da ação dos cinco fatores
t	–	Instantes de tempo
t_f	–	Instante de tempo final
t_0	–	Instante de tempo inicial
\mathbf{T}_{MQPR}	–	<i>Scores</i> de \mathbf{X}_{MQPR}
u	–	Potencial de ativação
\mathbf{U}_{MQPR}	–	<i>Scores</i> de \mathbf{Y}_{MQPR}

v	–	Quantidade de fotodiodo
V_{max}	–	Tensão de máxima
V_{min}	–	Tensão mínima
V_J	–	Velocidade de sedimentação
VM	–	Tensão de alimentação para o motor CC
V_s	–	Tensão de alimentação
VW	–	Tensão de alimentação para a válvula proporcional
w	–	Pesos sinápticos
\mathbf{W}_{MQPR}	–	Matriz de pesos
x	–	Sinais de entrada do Perceptron
\mathbf{X}_{MQPR}	–	matriz de variáveis predictoras
y	–	Sinal de saída do Perceptron
\mathbf{Y}_{MQPR}	–	matriz de variáveis respostas
z	–	Quantidade de medidas realizadas no tempo

LISTA DE ABREVIATURAS E SIGLAS

EMBRAPA	–	Empresa Brasileira de Pesquisa Agropecuária
IBGE	–	Instituto Brasileiro de Geografia e Estatística
IVP	–	Importância das Variáveis de Projeção
LIBS	–	Laser Induced Breakdown Spectroscopy
MLP	–	Rede neural artificial Perceptrons de múltiplas camadas
MQPINL	–	Mínimos Quadrados Parciais Iterativo Não Linear
MQPR	–	Mínimos Quadrados Parciais para Regressão
SCAD	–	Sistema de Controle e Aquisição de Dados
SiBCS	–	Sistema Brasileiro de Classificação de Solos
USDA	–	Departamento de Agricultura dos Estados Unidos

CAPÍTULO 1

INTRODUÇÃO

A palavra solo, dentre outras palavras comuns, dispõe de diversos significados. Popularmente, interpreta-se o solo como meio natural para o crescimento de plantas terrestres, sendo este, o entendimento comum da palavra, pois fornece alimentos, remédios, filtro natural para água, decomposição de resíduos sólidos e outras necessidades à vida humana. O solo, se estende continuamente sobre a superfície terrestre exceto na rocha nua, águas profundas, no gelo nu das geleiras ou áreas de geada perpétua. Neste sentido, o solo tem espessura (horizontes pedogenético) que pode ser determinada pela profundidade das raízes das plantas ou por escavações (USDA, 2014; LAL; SHUKLA, 2004; CHESWORTH, 2008).

Ao analisar o solo de determinada localidade, a textura de cada horizonte pedogenético é, normalmente, a primeira e mais importante propriedade a ser caracterizada, pois não está sujeita a alterações sendo considerada a propriedade perdurável do solo. Frações grosseiras maiores que 2mm de diâmetro (cascalhos, seixos, matacões e outras) podem afetar o comportamento do solo, mas não são classificados como pertencentes a terra fina seca ao ar, na qual melhor emprega-se o termo textura do solo (BRADY; WEIL, 2013).

A análise do tamanho das partículas que compõe a textura do solo, bem como outras ínfimas partículas, é objeto de estudo em diversas áreas, tais como, indústria do petróleo, indústria de mineração, agricultura, silvicultura, indústria pesqueira, programas espaciais entre outras (SYVITSKI, 2007). Para tanto, diversas metodologias têm sido desenvolvidas desde meados do século XIX, destacando-se o método por elutrição, onde a amostra é diluída em água para sedimentação (BERNHARDT, 1994).

Segundo Merkus (2009) o princípio da análise do tamanho das partículas (granulometria) por sedimentação se dá pelo fato de que partículas com diferentes tamanhos apresentem velocidades desiguais no fluido em repouso. Assim, observa-se as mudanças temporais e espaciais de concentração das partículas em sedimentação, abstraindo informações substanciais sobre a distribuição quantitativa de tamanhos caracterizada pela velocidade de seu movimento. A medição de tais distribuições é denominada análise de sedimentação, tendo sido desenvolvido os primeiros métodos para medir as distribuições entre o ano de 1925, destacando-se o método pela pipeta e o método pelo densímetro (areômetro).

O método pela pipeta foi introduzido por [Robinson \(1922\)](#), no qual a concentração de sólidos em sedimentação no nível de medição é mensurada amostrando, em intervalos de tempo, com a pipeta determinado volume e em sequência, após secagem, pesa-se a massa sólida a qual reflete o teor de concentração das partículas. Desta forma, a variação do peso a cada amostragem é a taxa de sedimentação, posteriormente convertida em distribuição quantitativa dos tamanhos das partículas. [Bouyoucos \(1926\)](#) apresenta uma forma mais rápida para obter a granulometria, o método pelo densímetro. O densímetro é introduzido em determinados intervalos no fluido contendo as partículas em sedimentação, e a variação da densidade lida em função do tempo, fornece a velocidade de sedimentação.

Após a Segunda Guerra Mundial, ampliou-se o desenvolvimento de métodos automatizados com medição livre de contatos manuais, mais precisos e com redução no tempo de ensaio ([BERNHARDT, 1994](#)). Neste período destaca-se os métodos fotoelétricos (foto sedimentômetro), os quais possuem como princípio de operação a medida da atenuação luminosa do feixe de luz atravessando o fluido contendo partículas em sedimentação ([ALLEN, 1990](#)). Em 1949, Brown e Skrebowski apresentam o primeiro método fotoelétrico baseado na atenuação de raios- X , sendo comercialmente conhecido como *X-ray sedimentation*. Décadas depois, [Vaz et al. \(1992\)](#) apresentam o método de atenuação por raios- γ .

Outros métodos automatizados de destaque, que não operam sob o princípio da sedimentação por força gravitacional são: i) zona elétrica de detecção ii) laser difração iii) atenuação por ultrassom e iv) análise por imagem. Em 1958, Herbert E. Kubitschek introduz o método zona elétrica de detecção para a contagem de partículas, até então utilizado para a contagem de células do sangue. Nesta técnica, determina-se o volume e a quantidade de partículas dispersas (em baixa concentração) em líquido condutor (eletrólito). As partículas em suspensão são agitadas em recipiente e extraídas uma a uma através de um orifício cilíndrico por meio de vácuo ou bomba dosadora. Dois eletrodos localizados em ambos os lados do orifício geram corrente elétrica constante, produzindo pulsos elétricos a cada passagem de partícula. A amplitude do pulso é proporcional ao volume da partícula ([MERKUS, 2009](#)).

[Hulst \(1957\)](#) formaliza em sua obra a dispersão da luz por pequenas partículas, a qual se transforma no método denominado laser difração. Neste método, o padrão de dispersão da luz monocromática (laser) incidindo no conjunto de partículas dispersas, é medido através de série de fotodetectores posicionados em diferentes ângulos,

de modo que os sinais recebidos são convertidos em distribuição granulométrica (ALLEN, 1990). O'Brien (1988) propõe método semelhante por atenuação de ondas sonoras de alta frequência (ultrassom), onde o retardo da velocidade das ondas pelo conjunto de partículas é medido em série de frequências e o padrão convertido em distribuição granulométrica.

Método robusto foi proposto por Johnston e Rosen (1976), onde as partículas são escaneadas por microdensitômetro de varredura óptica. As imagens capturadas são analisadas por software que fornece informações a respeito da granulometria, forma e textura, bem como a frequência de ocorrência em cada singularidade. Este método caracteriza-se como o principal no estudo da micromorfologia (ALLEN, 1990; SYVITSKI, 2007).

Ko e Shang (2011) apresentam método para obtenção em tempo real da granulometria de partículas minerais em operações industriais. O sistema desenvolvido captura imagens da superfície da amostra utilizando câmera fotográfica de 12,1 *megapixel*, e posteriormente analisa as imagens mediante rede neural artificial, fornecendo a distribuição do tamanho das partículas.

A utilização de sistemas inteligentes corroboram na análise solo-planta de forma recorrente. Na agricultura de precisão, o emprego de redes neurais artificiais é adotado como ferramenta que auxilia na combinação dos dados de solo e planta. Bernardi et al. (2004) descrevem o uso de redes neurais artificiais para estimar mapas de produtividade, mediante a avaliação da relação entre os parâmetros químicos e físicos do solo, dados de teores de nutrientes da soja e o mapa de produtividade obtido pela colheitadeira.

Haddad et al. (2012) utilizam redes neurais artificiais na quantificação de parâmetros químicos do solo obtidos por dispositivo portátil para espectroscopia de emissão óptica com plasma induzido por laser (LIBS). Nascimento et al. (2002) abordaram o uso de redes neurais artificiais para solucionar as imprecisões apresentadas pelo método laser difração no que tange aplicações com alta concentração de partículas e partículas não esféricas. O modelo neural é treinado mediante a correlação de imagens microscópicas do formato das partículas, classificando a distribuição granulométrica.

As funções de pedo transferência estimam indiretamente o comportamento de propriedades hidráulicas do solo ao mensurar propriedades básicas tais como textura, massa volúmica aparente, teor de carbono orgânico, entre outras. De posse de banco

de dados contendo informações sobre as propriedades básicas dos solos de 500 localidades ao norte do Irã, [Lake et al. \(2009\)](#) adotaram o uso das redes neurais artificiais para desenvolver funções de pedo transferência que permitam estimar propriedades físico-químicas e hidrológicas dos solos.

Apesar de diversas técnicas modernas à análise das partículas, o ensaio de sedimentação permanece como opção pertinente, e em alguns casos como no estudo da hidrossedimentologia, indispensável ([CARVALHO, 1994](#); [BERNHARDT, 1994](#)). No Brasil o ensaio de sedimentação caracteriza-se como o mais empregado devido ao baixo custo de aquisição, sendo os métodos da pipeta e do densímetro usualmente aplicados na medida da taxa de sedimentação. Estes, são padronizados no comunicado técnico da Embrapa por [Almeida et al. \(2012\)](#).

Técnica para automatizar a medição da taxa de sedimentação usando o princípio da foto sedimentação é apresentada por [Buah-Bassuah et al. \(1998\)](#) para obter a classificação textural do solo em aplicações agrícolas. Nesta técnica, o laser ($0,633\mu m$) é amplificado pelo colimador (lente) o qual incide sobre a placa com um orifício de $1mm$, permitindo o feixe luminoso atravessar o recipiente transparente contendo as partículas em sedimentação. Do lado oposto ao laser (180°), outro colimador entre o recipiente e o fotodetector amplifica o feixe luminoso atenuado pelas partículas em suspensão. Os sinais gerados pelo fotodetector, permitem obter a granulometria pela expressão de Stokes e lei de Beer-Lambert. Dois anos antes, [Caron et al. \(1996\)](#) apresentam técnica semelhante à análise granulométrica de minerais como carbetos de silício e gipsita.

Os métodos apresentados por [Caron et al. \(1996\)](#) e [Buah-Bassuah et al. \(1998\)](#) classificam a granulometria dos solos utilizando a Lei de Stokes na interpretação da taxa de sedimentação, que considera as partículas do solo esferas perfeitas, homogêneas e livre de influências de outras partículas. No entanto, o solo é portador de partículas heterogêneas com geometria variada, e portanto, ao adotar a Lei de Stokes a análise granulométrica sujeita-se a imprecisões.

Assim, é possível construir a hipótese primária: se cada solo sedimenta-se de forma diferente e se é possível realizar a análise de sedimentação automaticamente utilizando o princípio da foto sedimentação em multipontos, logo é possível mensurar o comportamento do solo, fornecendo multitaxas de sedimentação e inferindo o comportamento padrão de cada solo a ser reconhecido pela rede neural artificial. Desta forma, é possível identificar o solo e sua granulometria sem utilizar a Lei de Stokes. Tal desenvolvimento torna-se justificável pela portabilidade do dispositivo, acessi-

bilidade econômica e principalmente, permitir a obtenção das análises de amostras em campo.

O objetivo geral deste trabalho é desenvolver dispositivo que automatize o ensaio de sedimentação multipontos em solos e seja capaz de mensurar o comportamento das partículas do solo em sedimentação, utilizando rede neural artificial, reconhecendo características específicas do solo e sua granulometria. Ainda como objetivo têm-se: i) desenvolver dispositivo eletrônico para sedimentação; ii) apresentar o dispositivo em duas configurações, com e sem dispersão automática das partículas; iii) usar o princípio da foto sedimentação para mensurar a taxa de sedimentação, sem utilizar laser, fotodiodos e colimadores de alto custo; iv) aplicar método para obtenção dos dados de forma a representar o comportamento do solo em sedimentação; v) utilizar sistema de reconhecimento de padrões na classificação de algumas características do solo.

Este trabalho está organizado da seguinte forma: o Capítulo 2 conceitua o solo e apresenta a importância da compreensão da gênese do solo e suas propriedades, bem como salienta os aspectos do ensaio de sedimentação. No Capítulo 3 é apresentado de forma sucinta a técnica de reconhecimento de padrões por redes neurais artificiais e no Capítulo 4 é descrita a metodologia proposta. O Capítulo 5 dispõe os resultados com as discussões das análises dos dados e no Capítulo 6 é apresentada a conclusão.

CAPÍTULO 2

CLASSIFICAÇÃO E CARACTERÍSTICA DO SOLO

Este capítulo descreve de forma breve a definição do solo e sua formação. Define ainda os horizontes pedogenéticos a taxonomia e propriedades do solo como cor, textura, classes texturais e estrutura do solo. O capítulo encerra descrevendo as frações texturais das partículas do solo por meio do ensaio de sedimentação.

2.1 Formação do solo

O Manual Técnico de Pedologia desenvolvido pelo Instituto Brasileiro de Geografia e Estatística (IBGE) discorre sobre o atual Sistema Brasileiro de Classificação de Solos (SiBCS) (IBGE, 2007). Tanto o Manual Técnico de Pedologia quanto o Manual de Taxonomia do Solo (*Soil Taxonomy*) do Departamento de Agricultura dos Estados Unidos (*United States Department of Agriculture* – USDA) descrevem o termo solo, de forma resumida, como corpo natural composto por sólidos, líquidos e gases que ocorre na superfície terrestre, com capacidade de suportar sistema radicular em ambiente natural (USDA, 2014).

A rocha, mesmo com alto grau de consistência, intemperiza-se em corpo particulado proporcionando ambiente onde as raízes das plantas podem crescer recebendo nutrientes (LEPSCH, 2002). O intemperismo é o conjunto de transformações em determinada rocha envolvendo trocas entre litosfera, atmosfera, hidrosfera e biosfera a baixa temperatura e pressão atmosférica, com diversos fatores interagentes que influenciam seu curso (CHESWORTH, 2008).

Tal processo altera por decomposição química e desintegração física a rocha original. A ação física particiona a rocha em pedaços menores, fragmentando-os em partículas de areia e silte. No decorrer do processo químico o tamanho das partículas prosseguem em atenuação, transformando em argila, minerais menos resistentes ao intemperismo (BRADY; WEIL, 2013).

O solo é produzido através da ação de cinco fatores principais: i) **clima** (*cl*), destacando-se a precipitação pluvial e temperatura; ii) **biótico** (*o*), vegetação nativa, organismos vivos (especialmente os micróbios), animais e cada vez mais, os seres humanos; iii) **topografia** (*r*), inclinação, aspecto e posição do terreno; iv) **material de origem** (*p*), precursores geológicos ou orgânicos; v) **tempo** (*t*), período desde que os materiais de origem começaram a se transformarem (CHESWORTH, 2008; BRADY; WEIL, 2013).

Segundo Lepsch (2002) a expressão (2.1) descreve os principais agentes do intemperismo na forma implícita, onde S_R é o solo resultante da ação dos cinco fatores. Em (2.1) pode-se obter a influência de cada um destes fatores sobre a formação do solo. No entanto, esta é a expressão resumida, pois vários outros fatores interferem na transformação do solo. Os fatores climáticos e bióticos são considerados ativos no processo de formação, porque durante o decorrer do tempo e em dadas condições de relevo, atuam diretamente sobre o material de origem (a rocha) que, por conseguinte, é o fator resistivo ou passivo.

$$S_R = f(cl, o, r, p, t) \quad (2.1)$$

2.1.1 Horizontes pedogenéticos e componentes do solo

Cada solo de determinada localidade transforma principalmente sob influências da combinação dos cinco principais fatores da formação. A não uniformidade das ações dos processos físicos, químicos e biológico na adição, transformação, remoção e translocação do mineral original, ocasiona o conjunto diferente de porções sobrepostas **horizontes pedogenéticos**. Em cada seguimento de paisagem, lentamente formam-se os corpos naturais nos quais denominam-se **solos**. O conjunto de horizontes pedogenéticos em corte transversal que parte da superfície até o material similar ao que deu origem ao solo, é denominado **perfil do solo** (LEPSCH, 2002; BRADY; WEIL, 2013).

O **perfil do solo** é composto pelo menos por seis horizontes pedogenéticos principais, descritos pelas letras maiúsculas O, A, E, B, C e R, como ilustrado na Figura 2.1, adaptada de Brady e Weil (2013, p. 59), que retrata alguns dos principais horizontes pedogenéticos em determinado solo drenado de clima temperado e úmido. Cada horizonte individualmente pode ser constituído por **sub-horizontes pedogenéticos** que qualificam especificidades da porção do solo, designados através de sufixos (letras minúsculas), por exemplo: Bt, Ap ou Oi (LEPSCH, 2002; BRADY; WEIL, 2013).

Nos perfis do solo, nem toda camada sobreposta é horizonte pedogenético que se desenvolve como resultado dos processos de gênese dos solos. Materiais de origem como depósitos fluvioglaciais, sedimentos marinhos ou aluviões recentes, podem compor-se de várias camadas alternadas de partículas finas e grossas sedimentadas em episódios específicos. Portanto, o perfil de determinado solo pode não apresentar todos os horizontes pedogenéticos ilustrados na Figura 2.1, onde a ausência ou presença de cada

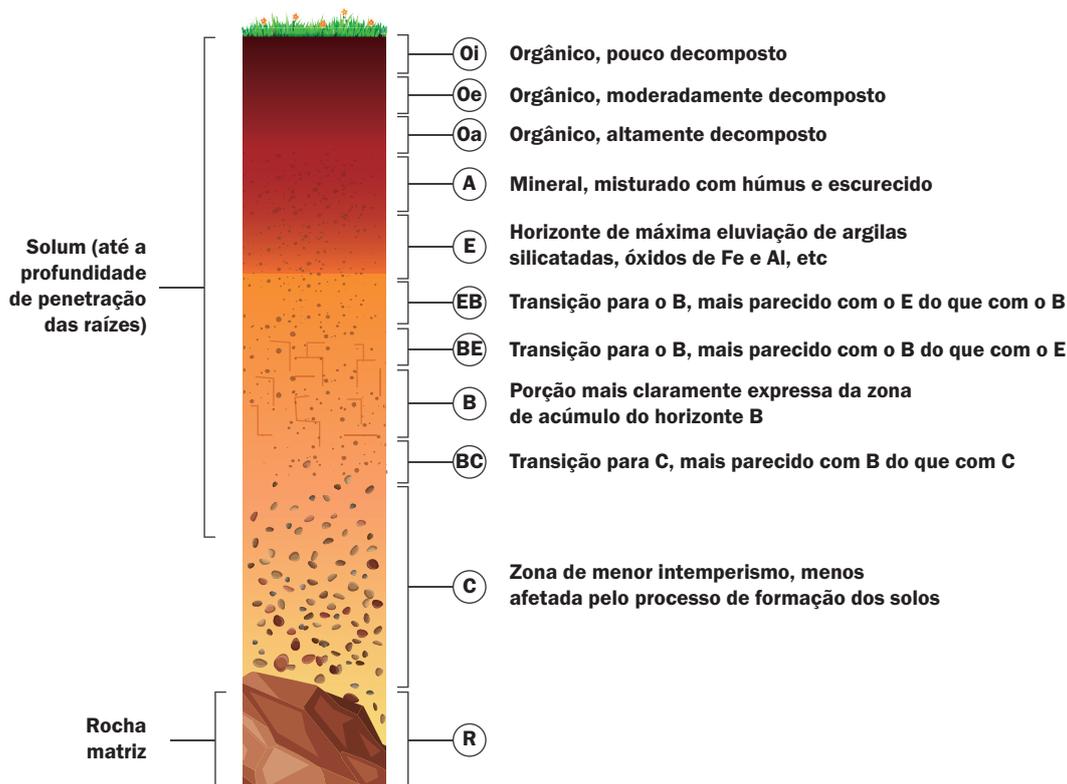


Figura 2.1 - Hipotético perfil de solo.

horizonte pedogenético determina a classe a qual o solo pertence. Para a classificação do solo (taxonomia) os atributos e propriedades de cada horizonte pedogenético são analisados individualmente, sendo o horizonte caracterizado denominado de **horizonte diagnóstico** (BRADY; WEIL, 2013).

Os horizontes pedogenéticos são constituídos por quatro componentes e três fases. Os componentes são: i) sólidos inorgânicos, ii) sólidos orgânicos, iii) água e iv) ar. As fases são: i) sólidos, ii) líquidos e iii) gasosos. A Figura 2.2, adaptada de Brady e Weil (2013, p. 59), ilustra a proporção do volume e interações na heterogeneidade dos componentes presente no horizonte mais superficial do solo.

Na Figura 2.2, a fase sólida é constituída de componentes inorgânicos formados de minerais primários e secundários originados da rocha primária. Os sólidos orgânicos são provenientes da adição de restos vegetais e animais. A fase líquida consiste em solução aquosa diluída de sólidos inorgânicos e orgânicos. A fração gasosa compreende de mistura de gases, por exemplo: nitrogênio, oxigênio, vestígios de dióxido de carbono, metano e óxido nitroso (LAL; SHUKLA, 2004).

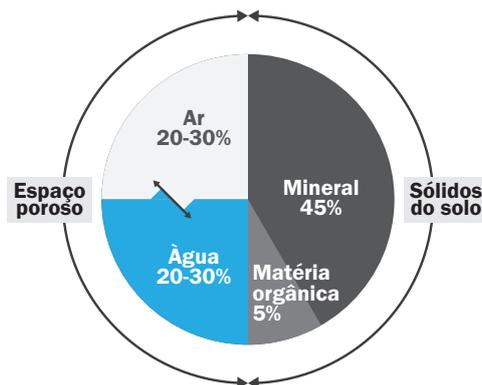


Figura 2.2 - Proporção de componentes e as fases do solo.

2.2 Taxonomia do solo

A finalidade da **taxonomia do solo** é estabelecer hierarquias de classes que intervenham na compreensão da relação entre os solos e suas características específicas (USDA, 2014). No Brasil, o IBGE em parceria com a Empresa Brasileira de Pesquisa Agropecuária (Embrapa), vem desenvolvendo o Sistema Brasileiro de Classificação de Solos (SiBCS), com o intuito de atender às condições tropicais a que está submetida a maior parte do Brasil. Tal sistema utiliza-se da categorização de classificação em seis níveis hierárquicos, desenvolvida no Manual de Taxinomia do Solo.

O sistema de taxonomia do solo apresenta seis níveis hierárquicos de forma decrescente: i) ordem, ii) subordens, iii) grandes grupos, iv) subgrupos, v) família e vi) série. A **ordem** baseia-se nas diferenças fundamentais da gênese do solo, fundamentando-se em propriedades do solo que indicaram o processo de sua concepção, existência ou inexistência dos principais horizontes diagnósticos (RICHARDSON; VEPRASKAS, 2001; SANTOS et al., 2006; USDA, 2014).

As **subordens** são referentes as condições ambientais nas quais as propriedades do solo formaram-se, indicando frequentemente o regime hidrológico do solo ou precipitação anual (RICHARDSON; VEPRASKAS, 2001; BRADY; WEIL, 2013; USDA, 2014). Os **grandes grupos** são subdivisões das subordens e são estabelecidos pelo tipo e arranjo dos horizontes pedogenéticos e/ou atividade da fração de argila (CHESWORTH, 2008; BRADY; WEIL, 2013; USDA, 2014).

Os **subgrupos** são concebidos para descrever vínculos com outras categorias no sistema ou propriedades especiais, como notas extras, por exemplo: o solo com rocha a baixa profundidade (CHESWORTH, 2008; BRADY; WEIL, 2013; USDA, 2014). A **família**

lia descreve propriedades morfológicas, físicas, químicas e mineralógicas que afetam a resposta do solo ao gerenciamento e manipulação para uso no desenvolvimento do sistema radicular (SANTOS et al., 2006; BRADY; WEIL, 2013; USDA, 2014).

A **série** é o nível mais específico do sistema de classificação, descrevendo especificidades relacionadas com o crescimento das plantas (principalmente no que diz respeito ao desenvolvimento do sistema radicular), relações solo-água-plantas e propriedades importantes nas concepções interpretativas para fins de engenharia, geotecnia e ambientais. Nos Estados Unidos e em diversos outros países, as séries recebem nomes, geralmente, de cidades, rios ou lagos (SANTOS et al., 2006; BRADY; WEIL, 2013; USDA, 2014). Os níveis **família** e **série** não foram formalizados no Brasil (SANTOS et al., 2006).

O Sistema Brasileiro de Classificação do Solos está categorizado em treze ordens, formadas pela combinação associativa de elementos com a terminação **ssolos**. A Tabela 2.1, adaptada de Santos et al. (2006, p. 70), dispõe os solos do Brasil e seus horizontes diagnósticos. A Tabela 2.2, adaptada de Lepsch (2002, p. 73), dispõe a taxonomia do latossolo, popularmente conhecido como terra roxa.

Tabela 2.1 - Solos do Brasil.

Ordens	Elemento Formativo	Termos de conotação e de memorização
Argissolo	Argi	Argilla. Acumulação de argila Tb (atividade baixa de argila com valor inferior a $27\text{cmol}_c/\text{kg}$) ou Ta (atividade alta de argila com valor igual ou superior a $27\text{cmol}_c/\text{kg}$) dessaturado de bases.
Cambissolo	Cambi	Cambiare, trocar ou mudar. Horizonte B incipiente.
Chernossolo	Cherno	Preto, rico em matéria orgânica.
Espodossolo	Espodo	Spodos, cinza vegetal. Horizonte Bspódico.
Gleissolo	Glei	Glei. Horizonte glei.
Latossolo	Lato	Lat, material muito alterado. Horizonte B latossólico.
Luvissolo	Luvi	Argilla. Luere, iluvial. Acumulação de argila com alta saturação por bases e Ta.
Neossolo	Neo	Novo. Pouco desenvolvimento genético.
Nitossolo	Nito	Nitidus, brilhante. Horizonte B nítico.
Organossolo	Organo	Orgânico. Horizonte H ou O hístico.
Planossolo	Plano	Planus. Horizonte B plânico.
Plintossolo	Plinto	Plinthus. Horizonte plíntico.
Vertissolo	Verti	Vertere, inverter. Horizonte vértico.

Tabela 2.2 - Taxonomia do Latossolo.

Nível categórico	Unidade sistemática
Ordem	Latossolo
Subordem	Latossolo Vermelho
Grande grupo	Latossolo Vermelho Eutroférico
Subgrupo	Latossolo Vermelho Eutroférico Típico
Família	Latossolo Vermelho Eutroférico Típico, textura argilosa, horizonte A moderado, oxidico hematítico
Série	Não estabelecidas

2.3 Características morfológicas

As características morfológicas do solo permitem determinar um tipo de solo entre os demais. Estas características são utilizadas no planejamento de engenharia e dependem da arquitetura e propriedades físicas do solo, influenciando no funcionamento do ecossistema. Algumas características morfológicas observadas são: i) **cor**, ii) **textura**, iii) **estrutura**, iv) consistência, v) porosidade, vi) nódulos e concreções minerais entre outras (BRADY; WEIL, 2013). Entre as várias características morfológicas, as três com maior representatividade são a cor, textura e estrutura.

2.3.1 Cor do solo

Dado o conjunto de circunstâncias como drenagem de água, aeração e conteúdo de matéria orgânica, a cor é a característica mais distinguível do solo, sendo útil para a identificação e delimitação dos horizontes pedogenéticos. Popularmente, o solo recebe nomes em função das várias tonalidades, por exemplo: terra roxa (do italiano *rossa* = vermelha), terras pretas entre outros. No entanto, nomes de classes do sistema de classificação pedológico atualmente em uso no Brasil, concernem à cor nomes como Chernossolo (do russo *chern* = escuro) e Latossolo Vermelho entre outros (LEPSCH, 2002).

A cor do solo inferi características importantes quanto a sua formação e uso. Solos maduros com alto teor de matéria orgânica decomposta (húmus) apresentam coloração preta e solos jovens podem ser fortemente relacionados com a cor do material original (rocha). São indicados como os principais agentes corantes do solo, os compostos de ferro em vários estados de oxidação e hidratação. O ferro desidratado e oxidado, hematita (Fe_2O_3), produz óxido avermelhado característico de vários solos tropicais. A goethita ($FeOOH$), ferro hidratado e oxidado, possui tonalidade amarelada enquanto o óxido de ferro reduzido e hidratado possui cor cinza. Portanto, a cor dos óxidos de ferro é relativo as condições de aeração e hidratação induzidas pela ausência ou presença de água (FOTH, 1990).

As cores do solo são convenientemente descritas utilizando-se de escala padronizada, no qual correntemente, adota-se variação da tabela *Munssell*, a *Munsell Soil Color Charts* (LEPSCH, 2002). O espectro de cores ilustrado na Figura 2.3, adaptada de USDA. (2017, p. 148), está organizado em: i) **matiz**, ii) **valor** e iii) **croma**. A **matiz**, é a medida da composição cromática, cor primária da luz percebida pelo olho (USDA., 2017). O **valor** é a leveza relativa da cor, ou seja, tons de cinza variando entre 0 a 10, onde 10 é o branco absoluto e 0 é o preto puro (CHESWORTH, 2008). O **croma**

é a pureza ou força relativa da cor espectral, indicando a intensidade de saturação de cinza neutro (SMITH; MULLINS, 2000).

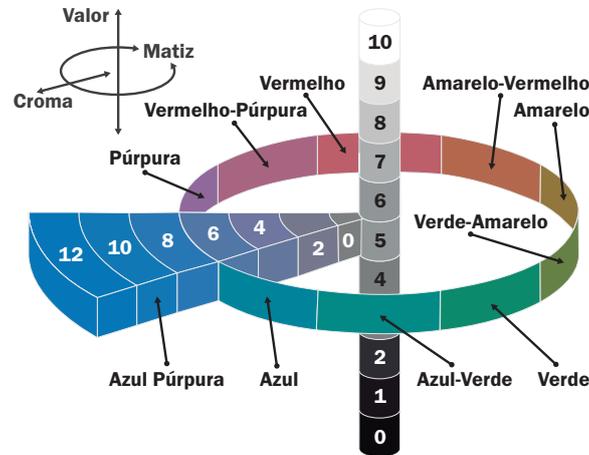


Figura 2.3 - Diagrama esquemático das relações entre matriz, valor e cromagem.

2.3.2 Textura do solo

A **textura do solo** é a proporção relativa de areia, silte (limo) e argila no solo e pode ser determinada mediante **análise granulométrica** (FOTH, 1990). Cada um destes três componentes, apresentam características próprias ao solo e detêm mineralogia distinta (SCHAETZL; ANDERSON, 2005). A distribuição do tamanho das partículas do solo recebe classificação de vários sistemas, sendo o mais reconhecido e amplamente utilizado (adotado também no Brasil) o do Departamento de Agricultura dos Estados Unidos (BRADY; WEIL, 2013; IBGE, 2007). A Figura 2.4, adaptada de Brady e Weil (2013, p. 108), ilustra os intervalos dos diâmetros pertencentes a cada fração.

A Figura 2.5, adaptada de Brady e Weil (2013, p. 109), ilustra a distribuição relativa de ocorrência do tipo de partículas minerais do solo. A areia e a maioria dos siltes são denominados **minerais primários**, oriundos de minerais liberados pela intemperie da rocha original. Os **minerais secundários**, quimicamente ativos, provêm da decomposição dos primários sendo em grande maioria compostos por argilas. A fração de tamanho do mineral de argila constituiu-se como uma família de minerais como flossilicato, caulinita, clorito, esmectite e vermiculita juntamente com argilas de óxido como hematita e goethita. No entanto, nem todas as partículas do tamanho de argila são minerais de flossilicato, podendo ocorrer na forma de minerais de quartzo e/ou amorfos (SCHAETZL; ANDERSON, 2005; BIRKELAND, 1984).

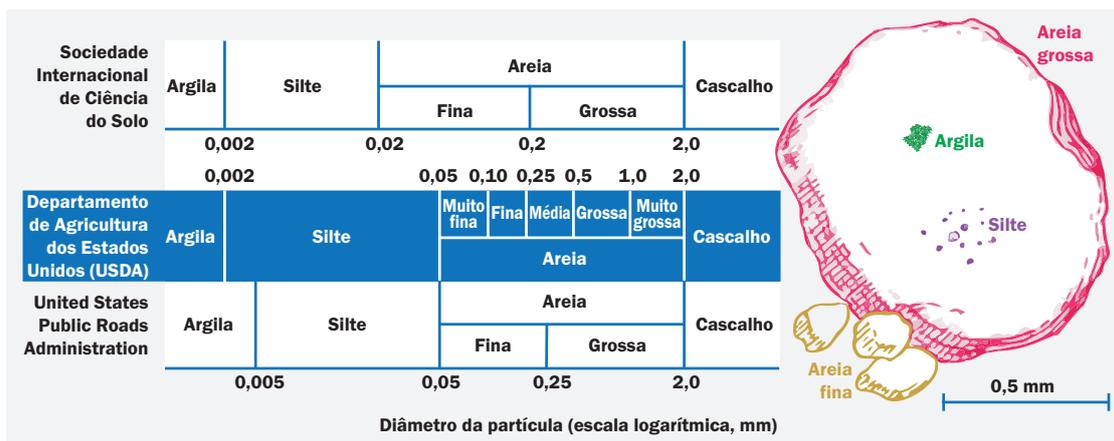


Figura 2.4 - Classificação do tamanho das partículas de solo.

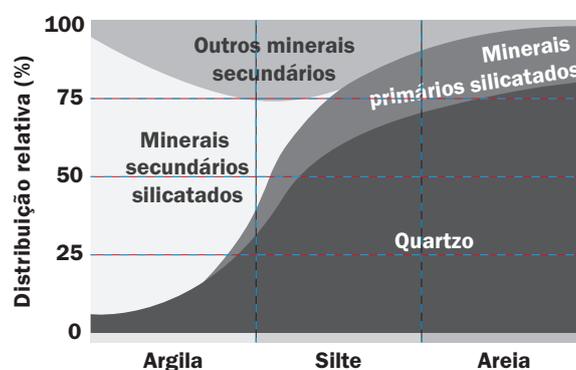


Figura 2.5 - Relação tamanho das partículas × tipos de minerais presentes.

2.3.2.1 Areia

Denomina-se como **areia**, partículas do solo menores que 2mm e maiores que $0,05\text{mm}$ de diâmetro. Tais partículas, dependendo do grau de intemperismo e abração, apresentam-se em formatos arredondados ou angulares e provocam ao tato sensação áspera, de textura grosseira (BRADY; WEIL, 2013).

Composta por fragmentos de rocha, a areia grossa é formada de diversos minerais, entretanto, predominantemente os grãos de areia são constituídos de quartzo, conforme ilustrado na Figura 2.5. Devido a predominância de partículas maiores, proporcionando maiores espaços vazios entre as partículas, solos arenosos são bem-arejados, soltos, propensos a seca, com fraca capacidade de retenção de água e de drenagem rápida (CHESWORTH, 2008; BRADY; WEIL, 2013).

2.3.2.2 Silte

Classifica-se como **silte**, partículas presentes em intervalo de diâmetro de $0,05mm$ a $0,002mm$. Estas manifestam semelhanças em forma e composição mineral com as partículas de areia, no entanto, não são visíveis a olho nu. Ao contrário da percepção áspera e arenosa ao tato, o silte ostenta sensação suave de maciez ou sedosidade, análoga a empregada pela farinha de trigo (FOTH, 1990; HILLEL, 2003; BRADY; WEIL, 2013).

A fração siltosa apresenta espaços vazios menores entre as partículas, inferindo comportamento de maior retenção aquosa se comparado a fração arenosa, tornando o solo com quantidades significativas de nutrientes para as plantas, quando formado por minerais intemperizáveis. No entanto, mesmo úmido não há comportamento pegajoso ou plástico. Solos com altos teores de silte e areia fina, estão susceptíveis à erosão pelo vento ou água, por apresentarem baixa taxa de pegajosidade e plasticidade (BRADY; WEIL, 2013; CHESWORTH, 2008; FOTH, 1990; HILLEL, 2003).

2.3.2.3 Argila

As partículas de **argila** têm diâmetros menores que $0,002mm$, é a fração coloidal¹. Pertencentes ao grupo dos minerais secundários, originando-se do intemperismo físico-químico dos minerais primários no decorrer da evolução do solo, as partículas de argila exibem formato semelhante a lamínas ou agulhas.

A superfície específica (área exposta pelo peso) da argila lhe garante volumosa retenção de água e outras substâncias. Os poros entre as partículas são infimamente minúsculos e tortuosos, propiciando vagarosa movimentação da água e ar. Quando úmida é pegajosa e facilmente moldada (plasticidade), ao passo que seca, expõe coesamente fragmentos rígidos cimentados. Em certas circunstâncias, a fração de argila pode incluir concentrações consideráveis de partículas finas não pertencentes à ordem mineralógica das argilas, por exemplo: óxidos de ferro ou carbonato de cálcio (BRADY; WEIL, 2013; HILLEL, 2003).

Comportamentos como expansão, contração, plasticidade, pegajosidade, capacidade de retenção de água, densidade e absorção química dependem do tipo e quantidade de argila. Em suspensão aquosa, partículas pertencentes a fração argila não

¹Se duas partículas de argila aproximarem suficientemente, íons carregados positivamente em uma camada circunvizinha a elas, atrairão as cargas negativas das duas partículas, agregando-as. As ligações **argila-argila** ocasionam aglomeração de partículas laminares de argila (THENG, 2012; BRADY; WEIL, 2013).

sedimentam-se rapidamente (BRADY; WEIL, 2013; HILLEL, 2003; THENG, 2012).

2.3.2.4 Classes texturais do solo

Segundo o Manual de Taxonomia do Solo (USDA., 2017) e o Manual Técnico de Pedologia do Brasil (IBGE, 2007), após medir as proporções percentuais de areia, silte e argila de determinada amostra do solo, o mesmo é caracterizado por intermédio das seguintes **classes texturais**: areia, silte, argila, areia-franca, franco, franco-argilo-arenosa, franco-argilosa, franco-arenosa, argilo-arenosa, muito argilosa, argilo-siltosa, franco-argilo-siltosa e franco-siltosa.

A Figura 2.6, adaptada de Santos et al. (2005, p. 19), ilustra as porcentagens relativas das classes texturais codificadas de forma triangular, estabelecendo a relação percentual entre as frações. O termo **solo franco** (ou textura franca) é apropriado para uma amostragem que detenha proporções semelhantes de areia, silte e argila (BRADY; WEIL, 2013).

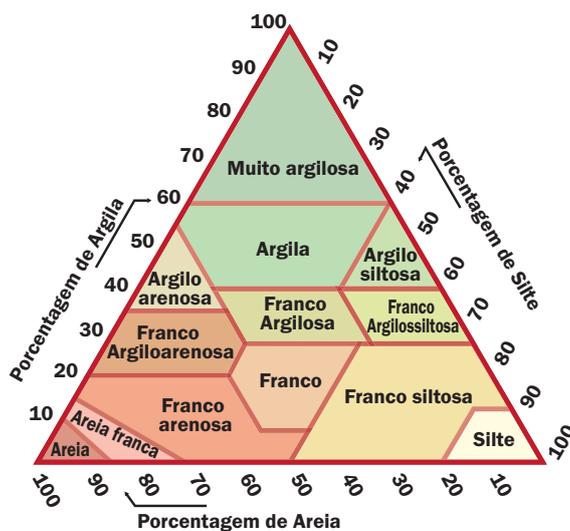


Figura 2.6 - Triângulo textural e representações das frações granulométricas.

2.3.3 Estrutura do solo

O estudo da **estrutura do solo** compreende formato, tamanho e arranjo das partículas formando agregados ou não e pode ser analisada sobre dois pontos de vista: i) **microestrutura** e ii) **macroestrutura** (IBGE, 2007). A **microestrutura** denota emprego específico e/ou limitado e suas análises (micromorfologia) dependem de sofisticados aparelhos e técnicas especiais. As técnicas de micromorfologia são

utilizadas na análise da organização das partículas, conforme expresso pelo arranjo espacial de seus componentes (sólidos, líquidos e gasoso) compreendendo sua forma, tamanho e frequência de ocorrência (SCHAETZL; ANDERSON, 2005).

A Figura 2.7, adaptada de Schaetzl e Anderson (2005, p. 27), exibe imagens de partículas de areia, silte e argila obtidas por intermédio de microscópio, onde: Figura 2.7(a) exibe grosseiros grãos de areia revestidos por materiais amorfos e orgânicos; Figura 2.7(b) grãos de areia fina aleatoriamente coberto por ligações de argila e silte; Figura 2.7(c) ponte de silte e argila; Figura 2.7(d) material amorfo revestido de poros e conectado a plaquetas de argila; Figura 2.7(e) e Figura 2.7(f) argilas de flossilicato com revestimento orientado.

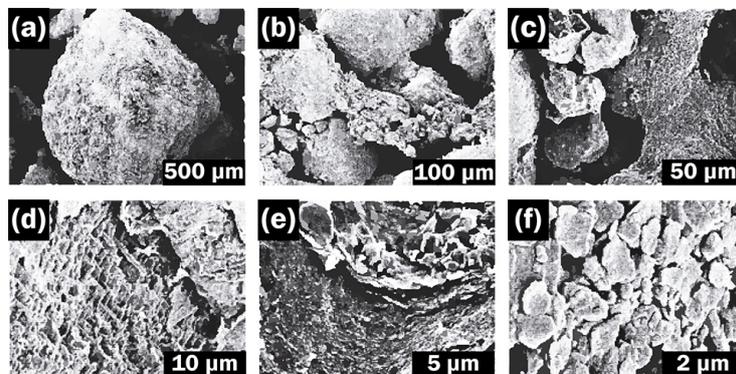


Figura 2.7 - Microscopia eletrônica de partículas do solo.

A **macroestrutura** do solo refere-se ao estudo em pedologia de caracterização e diagnose dos solos. Eventos aleatórios de diferentes intensidades fazem aparecer a união e arranjo padrão das partículas de areia, silte, argila e matéria orgânica formando unidades estruturais discretas denominadas de **agregados** (IBGE, 2007; BRADY; WEIL, 2013). A Figura 2.8, adaptada de FAO (2006, p. 45), ilustra as primaciais classes de agregados do solo. Agregados formados por agregação são provenientes da aglutinação das partículas do solo e adições externas do meio biótico. Agregados formados por separação são provenientes de fatores abióticos, forças físicas ou reações químicas. Agregados também podem ser formados por cimentação, fragmentação ou compactação.

2.4 Análise granulométrica do solo por sedimentação

A textura do solo pode ser determinada mediante a inúmeros procedimentos manuais ou automáticos, sendo o **ensaio de sedimentação** o mais comumente adotado.

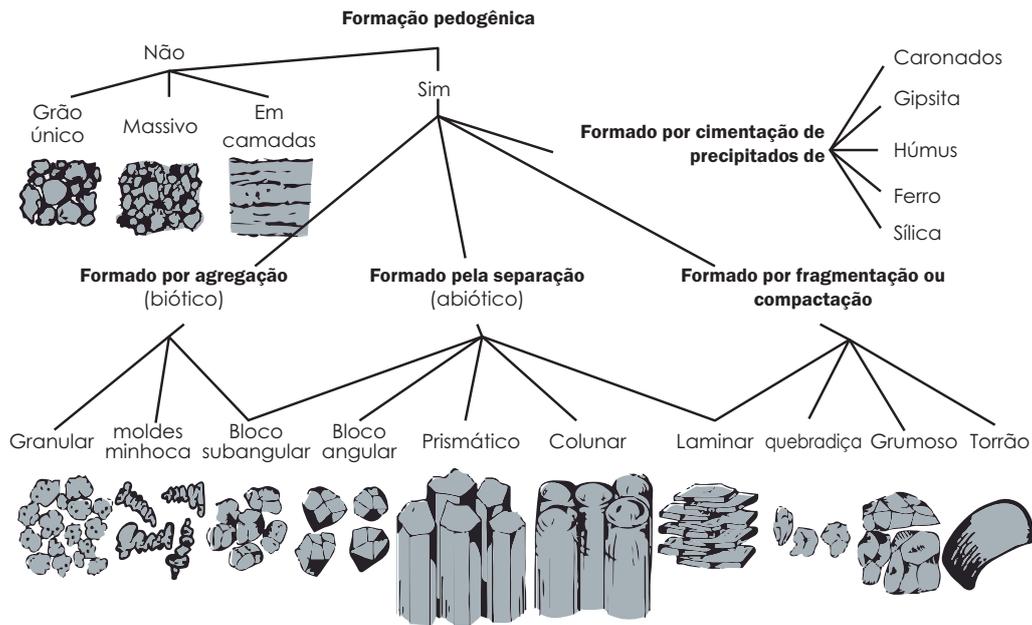


Figura 2.8 - Macroestrutura do solo e sua formação.

A Figura 2.9 ilustra de forma genérica, as etapas da realização do ensaio de sedimentação. O processo inicia-se submetendo solos na peneira, excluindo partículas maiores como areias grossas, cascalhos e calhaus. Em seguida a mesma é submergida em solução aquosa contendo dispersante químico como por exemplo, hexametáfosfato de sódio, durante período de 12 horas, para romper ligações argila-argila. Após esta fase, a amostra é submetida durante 15 minutos ao misturador motorizado com rotação superior a $9000rpm$ e hélice específica para dispersão, em seguida é levada à proveta graduada de $1000cm^3$ e completada até a graduação com mais água destilada, sendo deixada em repouso (ABNT, 1984; ABNT., 1986; LEPSCH, 2002).

No ensaio de sedimentação as partículas de areia (maiores e mais densas) assentam em alguns minutos, partículas de silte sedimentam em algumas horas e micropartículas e argilas permanecem em suspensão durante elevado período de tempo. Para solos com alta concentração de partículas de argila, a sedimentação completa excede período superior a 24 horas (VERRUIJT, 2008; CARVALHO, 1994; LEPSCH, 2002).

Os métodos comumente adotados para a medição da taxa de sedimentação (método pelo densímetro ou método de pipetagem), utilizam-se da Lei de Stokes. A Lei de Stokes aplicada a sedimentação assume que: i) as partículas são esféricas, ii) as partículas não são influenciadas por outras partículas, forças externas ou colisão com as paredes do recipiente e iii) a viscosidade do fluido e densidade específica das partículas são precisamente conhecidas. A Lei de Stokes é dada por (2.2), onde

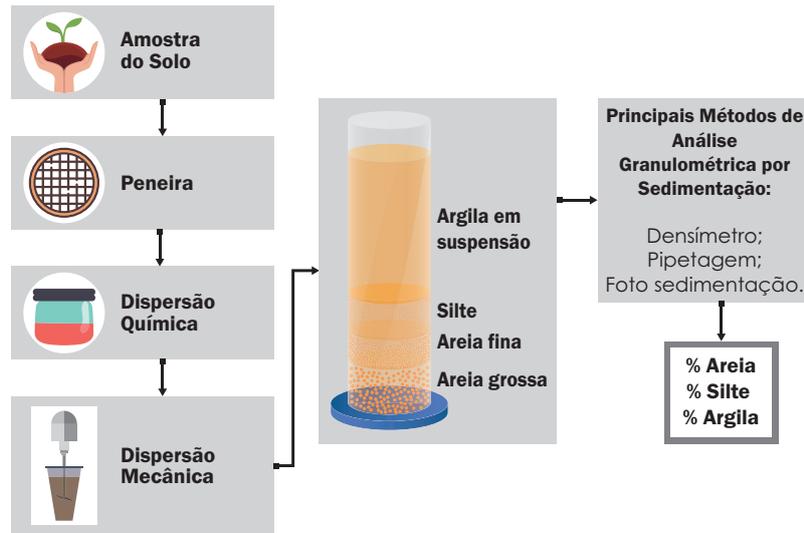


Figura 2.9 - Ilustração do ensaio de sedimentação.

V_J é a velocidade de sedimentação, γ_p é a densidade específica da partícula, γ_f é a densidade específica do fluido, D é o diâmetro da partícula esférica dada em metros (normalmente o diâmetro do quartzo é adotado) e μ é a viscosidade dinâmica do fluido (VERRUIJT, 2008; LAL; SHUKLA, 2004).

$$V_J = \frac{(\gamma_p - \gamma_f) \cdot D^2}{18\mu} \quad (2.2)$$

Os métodos que utilizam a Lei de Stokes estão sujeitos a imprecisões visto que as partículas do solo não são esferas perfeitas ou homogêneas e livres de influências de outras partículas, apresentando geometria, densidade específica e diâmetros distintos. Outra imprecisão para métodos manuais provém do manuseio com perturbações na amostra em sedimentação. Para eliminar estas perturbações, a solução é estimar automaticamente a quantidade de partículas em suspensão, passando pela amostra um feixe de luz (foto emissor). A Figura 2.10 ilustra a técnica de mensuração da taxa de sedimentação por foto medição, que determina a concentração de partículas mediante atenuação luminosa percebida na variação da tensão elétrica gerada nos terminais do foto receptor, portanto, a atenuação pode ser relacionada ao tamanho das partículas e velocidade de sedimentação (WASHINGTON, 1992).

Quando a luz passa pelo fluido com partículas sua intensidade diminui. A expressão (2.3) descreve tal relação:

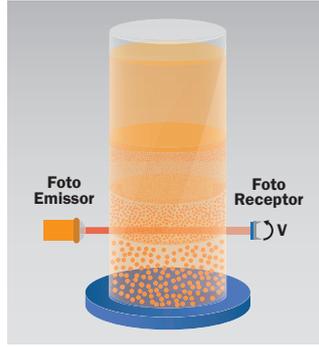


Figura 2.10 - Ilustração do processo de foto sedimentação.

$$\frac{I}{I_0} = e^{-\tau L_b} \quad (2.3)$$

onde L_b é o comprimento do caminho óptico, τ a turbidez e I_0 e I as intensidades incidentes e transmitidas. Instrumentos que operam com este princípio são intitulados como **foto sedimentômetros** (WASHINGTON, 1992; CHAMBINO et al., 2004; BERNHARDT, 1994). Comercialmente, foto sedimentômetros operam adotando raios X ou raios γ como feixe incidente sob a superfície dos foto detectores, para tanto, quanto menor a partícula a ser mensurada, menor deve ser o comprimento de onda (MERKUS, 2009; CHAMBINO et al., 2004).

O princípio da **foto sedimentação** é ilustrado na Figura 2.11, a qual apresenta o sinal elétrico produzido por uma esfera perfeita livre de forças externas (CHAMBINO et al., 2004). A resposta linear obtida pela passagem da esfera no feixe de luz é dada em três instantes de tempo t . Para os instantes de tempo inicial $t = t_0$ e instante de tempo final $t = t_f$, o foto receptor opera fornecendo tensão de saturação V_{max} para o feixe de luz incidente. No instante de tempo intermediário $t = \frac{t_f}{2}$, o foto receptor fornece tensão $V_{min} = 0$ devido a obstrução completa do feixe de luz monocromático pela esfera, dado que o diâmetro da esfera é maior que o comprimento de onda do feixe. Neste caso, V_{max} depende da distância L_b entre o foto emissor e o foto receptor, diâmetro do feixe de luz monocromático e eficiência do foto receptor na absorção do comprimento de onda recebido.

2.5 Considerações finais

Este capítulo descreveu os princípios fundamentais para a compreensão do solo como corpo dinâmico e complexo. O solo foi abordado em sua gênese como corpo único,

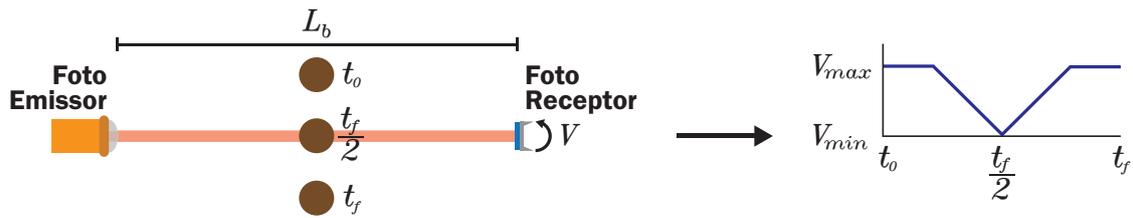


Figura 2.11 - Ilustração do sinal produzido por partícula esférica na foto sedimentação.

rocha primordial maciça, até sua complexa intempere em pequenas frações de areia, silte e argila. Mediante a estas explanações, pode-se compreender que o arranjo de partículas do solo aglutinadas forma único corpo que possui padrões relativos a cada região, tais singularidades podem ser mensuradas e identificadas mediante sistema de reconhecimento de padrões, que será apresentado no próximo capítulo.

CAPÍTULO 3

METODOLOGIA PARA RECONHECIMENTO DE PADRÃO

Este capítulo conceitua sucintamente o reconhecimento de padrões utilizando rede neural artificial. A abordagem apresenta aprendizado supervisionado com algoritmo de retropropagação do erro no modelo de rede neural artificial Perceptrons de múltiplas camadas

3.1 Reconhecimento de padrões

Atribuí-se o termo **reconhecimento de padrões** ao processo pelo qual o conjunto de sinais recebidos são classificados em categorias predeterminadas. O escopo deste processo é proveniente da repetida exposição da rede neural a seção de treinamento durante tempo ao qual, associa-se conjunto de padrões de entrada a categorias que cada padrão particular pertence. Posteriormente, apresenta-se à rede neural o novo padrão desconhecido, mas pertencente à mesma população de padrões anteriores (LEONDES, 1998; THEODORIDIS; KOUTROUMBAS, 2008).

Geralmente, o problema de reconhecimento de padrões é caracterizado como dilema de discriminação entre diferentes populações. A Figura 3.1 ilustra determinado indivíduo observando a dinâmica em tela, reconhecendo e classificando a imagem projetada. Esta classificação se dá por exclusão de classes as quais não foram associadas a imagem projetada aos olhos do receptor. Com isto, o cérebro define a **tomada de decisão** relacionando (serialmente e/ou paralelamente) o conjunto de entradas, por exemplo, gosto ou opinião. Portanto, o conceito dominante no reconhecimento de padrões é o de agrupamento, onde um grupo consiste em série de objetos semelhantes (padrões) agrupados. As fronteiras entre estas classes, são determinadas pelo processo de treinamento (HAYKIN, 2001; FRIEDMAN; KANDEL, 1999; BAEV, 1996).

O significado e grau de importância de cada padrão na coleção de padrões que norteiam o comportamento do indivíduo, advém da exposição cotidiana à aprendizado modelado por regras ou contingências. O comportamento modelado por regras prevê aprendizado supervisionado, com série de instruções que levam o indivíduo a obter sucesso em certa perspectiva. O comportamento modelado por contingências é formado mediante aprendizado por experimentação (NAVARICK, 1990; GALIZIO, 1979).

O indivíduo da Figura 3.1 em algum momento de sua formação comportamental, aprende de forma supervisionada as classes como mamíferos, humanos e gênero. Em outro momento, de forma experimental obteve sucesso com determinado padrão do

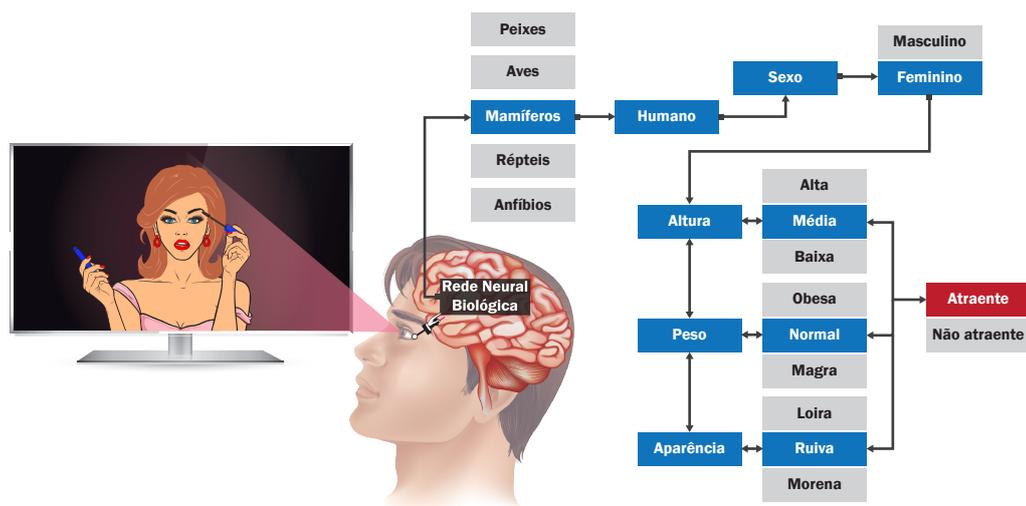


Figura 3.1 - Ilustração da classificação por reconhecimento de padrões biológicos.

gênero feminino ruiva, de altura média e peso normal. No entanto, apesar da ilustração hipotética, o que cada indivíduo caracteriza como padrão normal é subjetivo a sua modelagem comportamental (SKINNER, 1969).

O êxito provoca reforço aos estímulos neuronais, aumentando ou enfraquecendo as conexões sinápticas. Tais reforços são propagados aos neurônios biológicos compostos de soma, axônio e vários dendritos. Em seus dendritos, o neurônio recebe sinais de entrada de outros neurônios e quando o sinal excede determinado limiar, o neurônio é ativado. A ativação, originada por reação química, gera pulsos elétricos (denominado potencial de ação) propagados ao axônio (saída) do neurônio formando sinapses com outros neurônios (HANRAHAN, 2011; PERELMAN; GINOSAR, 2009; COPPIN, 2004; DEFELIPE, 1997).

O reconhecimento de padrões advindos da percepção experimental de especialista, pode ser modelado no sistema computacional reconhecido como redes neurais artificiais. Estes modelos computacionais, baseiam-se no sistema biológico e são constituídos de neurônios artificiais com conexões sinápticas (ARBIB, 2009; THEODORIDIS; KOUTROUMBAS, 2008).

3.2 Neurônio artificial

Neurônios artificiais são compreendidos com estrutura análoga ao biológico, processando informações com paralelismo e alta conectividade. A Figura 3.2, adaptada de Silva e Flauzino (2010, p. 34), ilustra o neurônio artificial com seus principais

elementos: i) sinais de entrada x , ii) pesos sinápticos w , iii) combinador linear Σ , iv) limiar de ativação b , v) potencial de ativação u , vi) função de ativação $g(u)$ e vii) sinal de saída y .

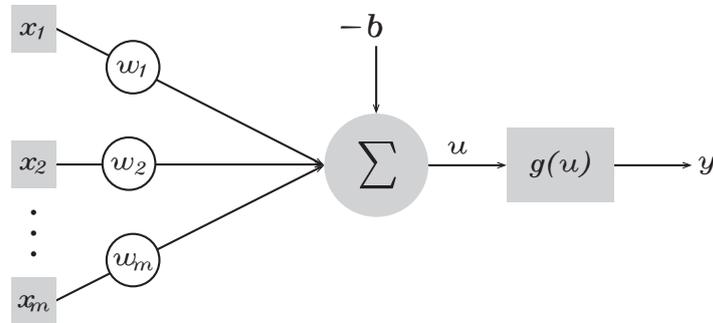


Figura 3.2 - Neurônio artificial.

Os **sinais de entrada** $\mathbf{x} = [x_1, x_2, \dots, x_m]$, são valores obtidos do meio externo e representam variáveis de específica aplicação. Estes sinais são similares aos impulsos elétricos externos percebidos pelos dendritos no neurônio biológico. No neurônio artificial, as ponderações exercidas pelas junções sinápticas do modelo biológico são representadas pelo conjunto de **pesos sinápticos** $w = [w_1, w_2, \dots, w_m]$. Avalia-se a relevância dos sinais de entrada multiplicando-os pelos respectivos pesos $x_i \cdot w_i$ com $i = 1, 2, \dots, m$ (BISHOP, 2006).

O **combinador linear** $\sum_{i=1}^m$, possui função de agregar todos os sinais de entrada ponderados pelos pesos sinápticos em único valor. A diferença entre o valor produzido pelo combinador linear e o limiar de ativação é denominado **potencial de ativação** u , dado por (3.1). O **limiar de ativação** b determina o patamar ao qual o resultado do combinador linear gere valor de disparo em direção à saída do neurônio. Se positivo $u > b$, o neurônio produzirá potencial amplificado e se negativo $u < b$, o neurônio produzirá potencial atenuado (SILVA; FLAUZINO, 2010).

$$u = \sum_{i=1}^m w_i \cdot x_i - b \quad (3.1)$$

O **sinal de saída** y é o valor final produzido pelo neurônio, limitado dentro do intervalo de valores aplicando o potencial de ativação u a função de ativação $g(u)$, dado por (3.2). As funções de ativação comumente adotadas são linear e tangente hiperbólica, nas quais, o intervalo normalizado da amplitude de saída é descrito

como unitário fechado $[0,1]$ ou alternativamente $[-1,1]$ (HANRAHAN, 2011).

$$y = g(u) \tag{3.2}$$

A rede neural artificial constituída de apenas uma camada neural, contendo nesta única camada somente um neurônio, é denominada **rede Perceptron**. O Perceptron é a estrutura mais simples da rede neural artificial na qual aplica-se a classificação de padrões ditos linearmente separáveis em lados opostos do hiperplano (HAYKIN, 2001).

3.3 Rede neural artificial Perceptrons de múltiplas camadas

A rede neural artificial Perceptrons de múltiplas camadas (*multilayer perceptron* – MLP), contempla em sua arquitetura: i) camada de entrada, ii) ao menos uma camada intermediária (oculta) e iii) camada de saída. A Figura 3.3(a), adaptada de Coolen et al. (2005, p. 50), ilustra a MLP com arquitetura generalizada contendo m entradas e L neurônios na camada de saída. A Figura 3.3(b) ilustra os n ciclos (épocas), onde a cada ciclo os pesos são ajustados. As variáveis de entrada (sinal de entrada) são representados por $x_1, x_2, \dots, x_i, \dots, x_m$ e os neurônios das camadas de saída por $S_1, S_2, \dots, S_i, \dots, S_L$. Entre as camadas de entrada e saída, há N camadas intermediárias $l = 1, 2, \dots, N$, contendo em cada camada m_l neurônios, cujo os sinais de saída são descritos por y_i^l , com $i = 1, 2, \dots, m_l$. O peso sináptico conectando o j -ésimo neurônio da camada $l - 1$ ao i -ésimo neurônio da camada l é descrito por w_{ij}^l , onde $j = 1, 2, \dots, m_{l-1}$.

Redes neurais artificiais Perceptrons de múltiplas camadas, buscam estabelecer o correto mapeamento entrada-saída. Os dados de entrada e saída compõem o **banco de dados** e são provenientes de determinada aplicação e/ou problema no mundo real, os quais são aplicados a entrada da rede (PURI et al., 2016).

As principais áreas de aplicações das MLP são aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas (SILVA; FLAUZINO, 2010; SILVA, 2018; SILVA, 2018). As redes Perceptrons de múltiplas camadas têm sido aplicadas na classificação de padrões por meio do seu treinamento de modo supervisionado com o algoritmo de **retropropagação de erro** (*backpropagation*). A aprendizagem por retropropagação do erro constitui-se de dois passos permeando as diferentes camadas da rede: i) **passo para frente**, a propagação (*forward*) e ii) **passo para trás**, a retropropagação

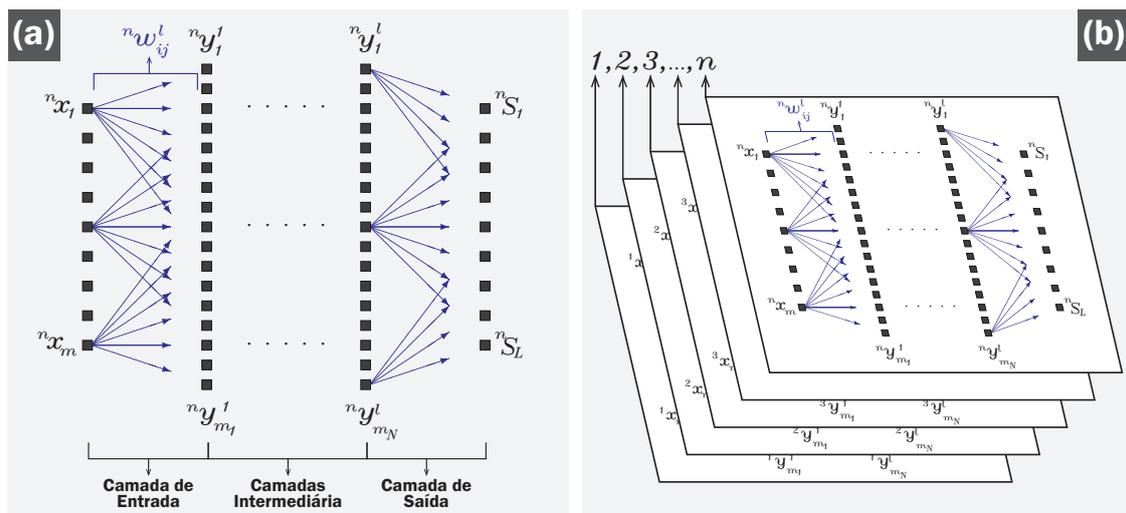


Figura 3.3 - Ilustração de rede Perceptron multicamadas: (a) topologia ou geometria da rede multicamadas e (b) ciclo de n iterações.

(*backward*). Os passos de propagação e retropropagação são aplicados meramente na etapa de treinamento. Para a fase de operação, pós aprendizado, aplica-se apenas a propagação (HU; HWANG, 2002; HAYKIN, 2001).

O algoritmo de propagação do erro baseia-se na regra de aprendizagem por correção do erro, onde os pesos sinápticos são atualizados a cada n ciclos pré definidos e/ou até o erro aproximar-se do valor pré determinado, buscando a convergência entre os sinais aplicados na entrada e a resposta desejada na saída da rede (ARBIB, 2009; HASENFUSS et al., 2008; GALUSHKIN, 2007).

No **passo para frente**, os neurônios da primeira camada oculta ($l = 1$) recebem os sinais das variáveis de entrada, sendo estes ponderados pelos respectivos pesos e ativados como dado por (3.3), onde g é a função de ativação e $j = 1, 2, \dots, m$ considerando o limiar de ativação b . O estado y_i^1 é então propagado para as demais camadas intermediárias, onde (3.4) é a generalização da propagação até a camada $l = N$. Por fim, a resposta final produzida pela rede é então gerada pelos neurônios S_i da camada de saída $l = N + 1$, como dado por (3.5). Neste passo os pesos sinápticos da rede são todos fixos (COOLEN et al., 2005; HE; XU, 2010).

$${}^n y_i^1 = g \left(\sum_{j=1}^m {}^n w_{ij}^1 \cdot {}^n x_j \right) \quad (3.3)$$

$${}^n y_i^l = g \left(\sum_{j=1}^{m_{l-1}} {}^n w_{ij}^l \cdot {}^n y_j^{l-1} \right), \quad (l > 1) \quad (3.4)$$

$${}^n S_i = g \left(\sum_{j=1}^{m_N} {}^n w_{ij}^{N+1} \cdot {}^n y_j^N \right) \quad (3.5)$$

O erro obtido em cada neurônio da camada de saída é calculado por (3.6), onde ME_i é a resposta desejada. O erro total da rede em cada iteração n é dado por (3.7) (COOLEN et al., 2005; BRASPENNING, 1995).

$${}^n e_i = {}^n S_i - {}^n ME_i \quad (3.6)$$

$${}^n E = \frac{1}{2} \sum_{i=1}^L ({}^n S_i - {}^n ME_i)^2 \quad (3.7)$$

O sinal de erro é então propagado para trás através da rede em oposição as conexões sinápticas (*backward*). No passo para trás, todos os pesos sinápticos são ajustados de acordo com o gradiente local δ_i , dado por (3.8) que descreve o gradiente local da camada de saída, onde $g'(x) = G[g(x)]$. O gradiente local para ajuste das camadas intermediárias é dado por (3.9) (COOLEN et al., 2005; BRASPENNING, 1995).

$${}^n \delta_k^{N+1} = {}^n e_k^{N+1} \cdot G'({}^n S_k), \quad 1 \leq k \leq L \quad (3.8)$$

$${}^n \delta_{i_l}^l = \sum_{i_{l+1}=1}^{N_{l+1}} {}^n \delta_{i_{l+1}}^{l+1} \cdot {}^n w_{i_{l+1}i_l}^{l+1} \cdot G'({}^n y_{i_l}^l), \quad 1 \leq i_l \leq N_l \quad (3.9)$$

Em (3.10) é descrita a lei de formação para a correção dos pesos sinápticos retropropagados pelas l camadas com $l = 2, 3, \dots, N + 1$, onde para $y_j^1 = x_i$ e $y_j^{N+1} = S_i$. A taxa de aprendizagem η define as variações nos valores dos pesos sinápticos de uma iteração para outra (COOLEN et al., 2005; HAYKIN, 2001; BRASPENNING, 1995).

$${}^{n+1} w_{ij}^l = ({}^n w_{ij}^l) + \eta ({}^n \delta_i^l) ({}^n y_j^{l-1}) \quad (3.10)$$

Na aprendizagem por retropropagação, após o treinamento com tantos exemplos quanto possíveis, espera-se que a rede seja capaz de generalizar. Segundo Haykin (2001), a rede **generaliza** quando o mapeamento entrada-saída for correto para dados não expostos à rede em treinamento. A Figura 3.4, adaptada de Haykin (2001, p. 233), ilustra situação hipotética com adequação correta na generalização, onde os pontos marcados como dados de treinamento são resultantes dos dados apresentados a rede na fase de treinamento e o ponto generalização é o resultado da interpolação realizada pela rede.

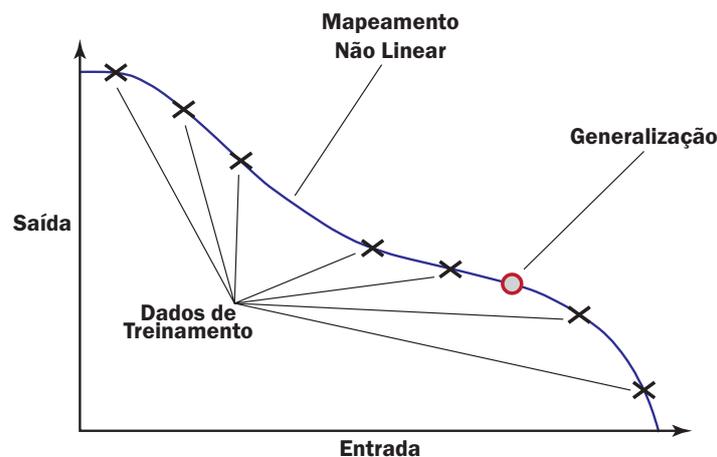


Figura 3.4 - Ilustração hipotética de generalização adequada.

Para que a rede possa generalizar é necessário evitar a falta (*underfitting*) ou o excesso (*overfitting*) de treinamento (SILVA, 2018). Neste contexto, a ferramenta estatística **validação cruzada**, é adotada para orientar a correta generalização. A Figura 3.5 ilustra o processo da validação cruzada, onde o banco de dados a ser mapeado pela rede é dividido aleatoriamente em: i) conjunto de treinamento **A** e ii) conjunto de teste **B**. O conjunto de treinamento é dividido em dois subconjuntos: de estimação **A₁** e de validação **A₂** (PURI et al., 2016; HAGAN; BEALE, 2014; COOLEN et al., 2005; HAYKIN, 2001).

O subconjunto de estimação é apresentado a rede para mapeamento entrada-saída aplicando os passos *forward* e *backward* a cada n época para o ajuste dos pesos sinápticos, até atingir o erro mínimo desejado ou n épocas pré-definidas. Após a estimação, a rede deve ser apresentada ao subconjunto de validação, onde apenas o passo *forward* é aplicado afim de que os pesos ajustados na etapa de estimação, possam apresentar generalização para o subconjunto de dados diferente daquele

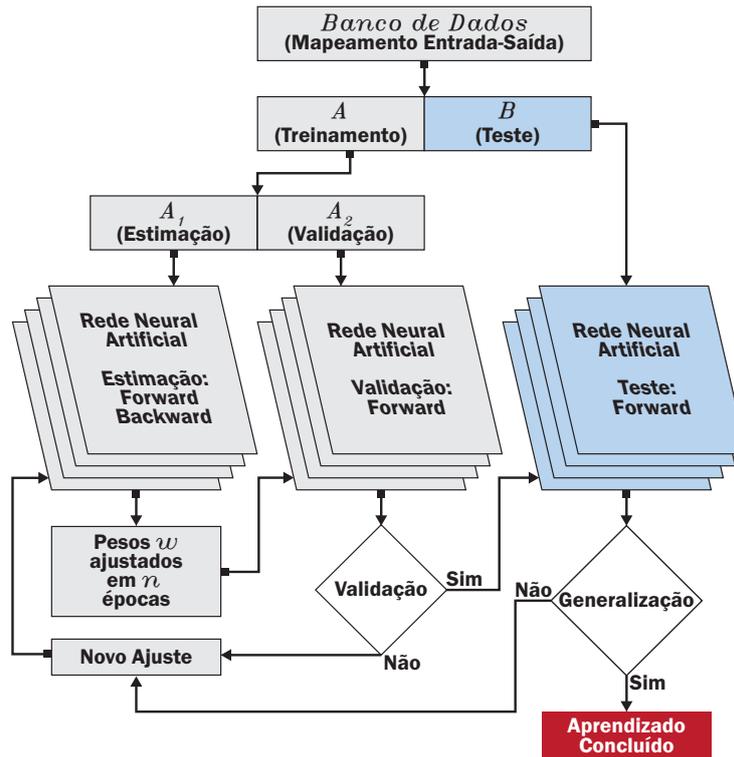


Figura 3.5 - Ilustração do método de validação cruzada.

usado para estimar os pesos sinápticos. Caso a validação não seja satisfatória, a rede deve receber novo ajuste. Para garantir a generalização, o modelo estimado e validado é apresentado ao conjunto de teste com dados diferentes do conjunto de treinamento (PURI et al., 2016; HAGAN; BEALE, 2014; COOLEN et al., 2005; HAYKIN, 2001).

A quantidade de sinais de entradas, camadas intermediárias, neurônios nas camadas intermediárias e neurônios na camada de saída (topologia da rede), são empiricamente definidos durante o processo de aprendizagem com os dados do conjunto de treinamento a qual escolhe-se a topologia com melhor desempenho. Outra alternativa para garantir melhor assertividade na escolha da topologia ótima, é adotar o uso de algoritmos de otimização.

3.3.1 Algoritmo genético

Os algoritmos de otimização podem ser divididos em dois grupos: i) determinísticos e ii) heurísticos. Os métodos determinísticos são processos analíticos altamente dependente do valor inicial e da derivada da função de avaliação. Os métodos heurísticos independem das derivadas da função de avaliação e utilizam variáveis aleatórias na

tomada de decisão. Vários são os algoritmos de otimização heurísticos, entre eles um dos mais utilizados é o algoritmo genético (CALIXTO, 2012; GEN et al., 2008).

O algoritmo genético é método heurístico de busca aleatória inspirado no desenvolvimento evolutivo biológico. Propriedades como hereditariedade, mutação, seleção natural e recombinação são análogas ao modelo biológico, onde estas propriedades são aplicadas para aprimoramento dos indivíduos que compõem a população. Cada indivíduo é a representação codificada para possível solução de determinado problema, sendo caracterizado como cromossomo codificado no vetor $\mathbf{c}_{GA_{m_{GA}}}$, dado por (3.11), onde seus elementos são análogos a genes e cada gene representa parâmetros a serem otimizados. A coleção de indivíduos forma a população, dada por (3.12), onde m_{GA} indica a quantidade de indivíduos da população e n_{GA} a quantidade de genes (KRAMER, 2017; PASSINO, 2005).

$$\mathbf{c}_{GA_{m_{GA}}} = [c_{GA_1}, c_{GA_2}, c_{GA_3}, \dots, c_{GA_{n_{GA}}}] \quad (3.11)$$

$$\mathbf{P}_{GA_{n_{GA}} \times m_{GA}} = \begin{bmatrix} c_{GA_{1,1}} & c_{GA_{1,2}} & c_{GA_{1,3}} & \cdots & c_{GA_{1,n_{GA}}} \\ c_{GA_{2,1}} & c_{GA_{2,2}} & c_{GA_{2,3}} & \cdots & c_{GA_{2,n_{GA}}} \\ c_{GA_{3,1}} & c_{GA_{3,2}} & c_{GA_{3,3}} & \cdots & c_{GA_{3,n_{GA}}} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ c_{GA_{m_{GA},1}} & c_{GA_{m_{GA},2}} & c_{GA_{m_{GA},3}} & \cdots & c_{GA_{m_{GA},n_{GA}}} \end{bmatrix} \quad (3.12)$$

A Figura 3.6 ilustra a estrutura do algoritmo genético clássico, onde a população inicial, gerada aleatoriamente, é aplicada na função de avaliação para obter a aptidão de cada indivíduo. Caso algum indivíduo da população inicial satisfaça o critério de parada, o algoritmo cessa o processo, retornando a solução ótima ou otimizada. Populações iniciais que não obtiveram indivíduos que satisfaçam o critério de parada, são submetidas a manipuladores e operadores genéticos (GEN et al., 2008).

No algoritmo genético clássico, os manipuladores genéticos são: i) **elitismo** e ii) **seleção**. Estes manipuladores genéticos garantem a manutenção dos melhores indivíduos na população. A função de avaliação é o elo entre o algoritmo genético e o problema real. Cada indivíduo após passar pela função de avaliação recebe uma nota. Esta nota (aptidão do indivíduo) indica a distância de determinado indivíduo da solução ótima. No manipulador genético **elitismo**, o indivíduo que obtém a melhor nota (maior valor no caso de maximização e menor valor no caso de mini-

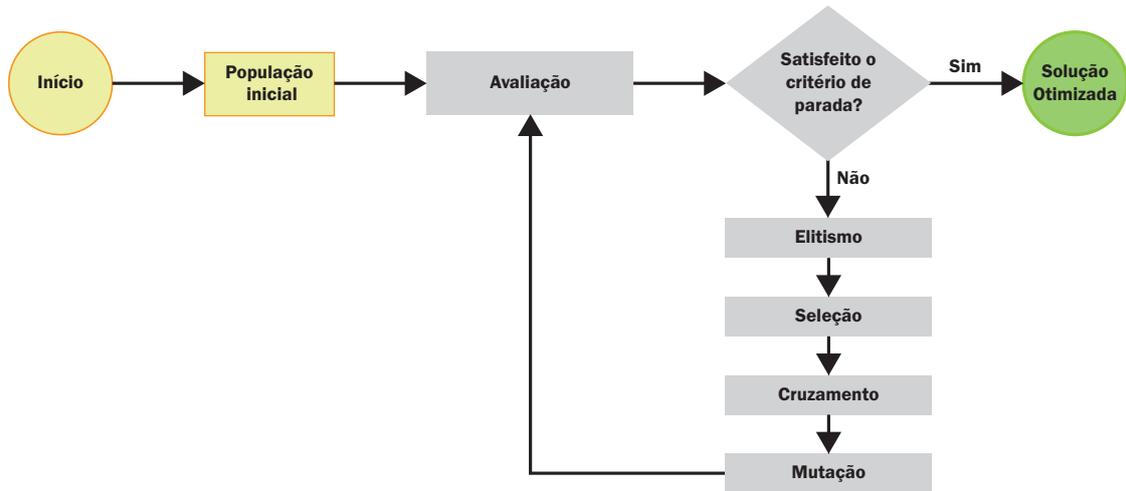


Figura 3.6 - Estrutura do algoritmo genético clássico.

mização) é copiado e guardado para ser inserido na nova população g_{GA} (CALIXTO, 2012).

Existem vários manipuladores genéticos de **seleção**, entre eles um dos mais utilizados é a **seleção por torneio**. No torneio, escolhe-se o valor $2 \leq \tau_{GA} \leq m_{GA}$ de indivíduos da população, onde τ_{GA} é a quantidade de indivíduos que competem pelo direito de ser os progenitores de novos indivíduos para a próxima geração. Caso τ_{GA} próximo de m_{GA} , os indivíduos com maior nota serão selecionados, no entanto, há perda da diversidade na população se τ_{GA} próximo de dois. Indivíduos que participam do torneio e apresentam melhor função de avaliação, são eleitos para gerarem novos indivíduos (CALIXTO, 2012).

No algoritmo genético clássico os operadores genéticos são: **cruzamento** e **mutação**. O operador **cruzamento** é responsável pela troca genética entre os indivíduos, permitindo que indivíduos de gerações futuras herdem características dos indivíduos das gerações anteriores. Tem-se como exemplo o operador de cruzamento **simples**, para o qual dois cromossomos escolhidos aleatoriamente, $\mathbf{c}_{GA1,n_{GA}}$ e $\mathbf{c}_{GA2,n_{GA}}$, são submetidos a variável probabilística binária de decisão η_{GA} para a formação do novo cromossomo. Caso $\eta_{GA} = 1$ troca-se $\mathbf{c}_{GA1,n_{GA}}$ por $\mathbf{c}_{GA2,n_{GA}}$, e caso $\eta_{GA} = 0$ não ocorre troca genética.

O operador de **mutação** introduz variabilidade genética na população, selecionando aleatoriamente e provocando perturbação no valor de determinado gene. Calixto (2012) descreve o operador de mutação não uniforme, onde $\mathbf{c}_{GA m_{GA}, i=1,2,\dots,n_{GA}} \in [a_{GA}, b_{GA}]$ é o gene a ser mutado, e $\mathbf{c}'_{GA m_{GA}, i}$ o resultado da operação dada por

(3.13) é aplicada em todas as gerações. O valor a ser mutado em cada gene é dado por (3.14), onde r_{GA} é o número aleatório no intervalo $(0 : 1]$, β_{GA} é o parâmetro a ser escolhido que determina o grau de dependência do número de gerações e $\Delta(g_{GA}, y_{GA})$ retorna o valor no intervalo $(0, y_{GA}]$ tal que a probabilidade de retornar número próximo de zero aumenta a medida que as gerações vão se aproximando do número máximo de gerações g_{GAmax} .

$$\mathbf{c}'_{GA_{m_{GA},i}} = \begin{cases} \mathbf{c}_{GA_{m_{GA},i}} + \Delta\left(g_{GA}, b_{GA} - \mathbf{c}_{GA_{m_{GA},i}}\right) & \text{se } \tau_{GA} = 0 \\ \mathbf{c}_{GA_{m_{GA},i}} - \Delta\left(g_{GA}, \mathbf{c}_{GA_{m_{GA},i}} - a_{GA}\right) & \text{se } \tau_{GA} = 1 \end{cases} \quad (3.13)$$

$$\Delta(g_{GA}, y_{GA}) = y_{GA} \cdot \left[1 - r_{GA}^{\left(1 - \frac{g_{GA}}{g_{GAmax}}\right)^{\beta_{GA}}} \right] \quad (3.14)$$

Desta forma, espera-se que o algoritmo genético encontre soluções otimizadas, mas não necessariamente ótimas. Para tanto, por ser método de busca aleatória para encontrar a melhor solução, o algoritmo genético pode ser simulado por longo período de tempo, caso o problema tenha elevado números de parâmetros, dados ou variáveis. Uma forma de reduzir o tempo consumido em simulações é aplicando o método para redução do tamanho de dados ou variáveis.

3.3.2 Análise de sensibilidade na projeção de variáveis

Vários problemas em análise de sistema exigem a redução de dados ou o selecionamento de variáveis que tenham real importância para determinado modelo. O treinamento para reconhecimento de padrões da MLP se torna demasiadamente lento quando aplicada a elevada quantidades de variáveis ou dados. O método **mínimos quadrados parciais** para regressão (MQPR), permite a redução de dados de variáveis preditoras e variáveis respostas, criando novas componentes que são estimadoras dos dados originais. Ao aplicar o MQPR em determinado sistema, o método de importância das variáveis de projeção (IVP) nos mínimos quadrados parciais, permite medir a contribuição de cada variável preditora, tornando possível selecionar as que mais contribuem para que o treinamento da rede ocorra com quantidade menor de variáveis.

A Figura 3.7 ilustra o método MQPR que relaciona duas matrizes \mathbf{X}_{MQPR} , matriz $n_{MQPR} \times \zeta$ de variáveis preditoras, e \mathbf{Y}_{MQPR} , matriz $n_{MQPR} \times m_{MQPR}$ de variáveis respostas, com relação expressa $\mathbf{Y} = \mathbf{X} \cdot \mathbf{B}_{MQPR}$, onde \mathbf{B}_{MQPR} é a matriz dos

coeficientes de regressão de ordem $\zeta \times m_{MQPR}$, dada por $\mathbf{B}_{MQPR} = \mathbf{W}_{MQPR} \cdot \mathbf{C}_{MQPR}^T$, onde T indica matriz transposta. No modelo n_{MQPR} é a quantidade de observações com $i = 1, 2, \dots, n_{MQPR}$, ζ é o número de variáveis em \mathbf{X}_{MQPR} com $j = 1, 2, \dots, \zeta$ e m_{MQPR} é o número de variáveis em \mathbf{Y}_{MQPR} com $k = 1, 2, \dots, m_{MQPR}$. O MQPR extraí pequena quantidade de novas variáveis de \mathbf{X}_{MQPR} e \mathbf{Y}_{MQPR} , denominadas *scores*, representadas respectivamente por \mathbf{T}_{MQPR} e \mathbf{U}_{MQPR} , onde estas são matrizes $n_{MQPR} \times \xi$ para as quais ξ representa as novas componentes ortogonais que descrevem as variáveis originais. \mathbf{W}_{MQPR} e \mathbf{P}_{MQPR} são pesos de \mathbf{X}_{MQPR} e \mathbf{C}_{MQPR} pesos de \mathbf{Y}_{MQPR} para obter respectivamente, \mathbf{T}_{MQPR} e \mathbf{U}_{MQPR} (KRISHNAN et al., 2010; WOLD et al., 2001).

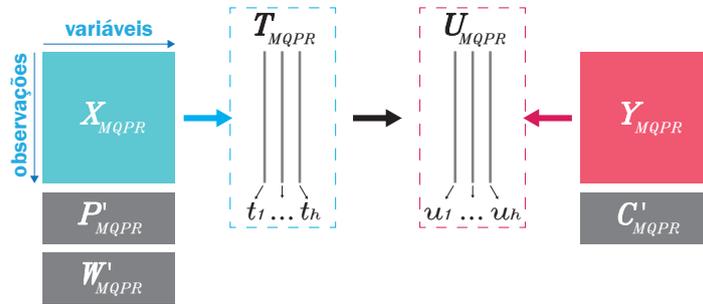


Figura 3.7 - Arranjo dos dados no mínimos quadrados parciais para regressão.

As matrizes \mathbf{X}_{MQPR} e \mathbf{Y}_{MQPR} são decompostas respectivamente em (3.15) e (3.16), onde \mathbf{F}_{MQPR} e \mathbf{G}_{MQPR} são matrizes de erros.

$$\mathbf{X}_{MQPR} = \mathbf{T}_{MQPR} \cdot \mathbf{P}_{MQPR}^T + \mathbf{F}_{MQPR} \quad (3.15)$$

$$\mathbf{Y}_{MQPR} = \mathbf{U}_{MQPR} \cdot \mathbf{C}_{MQPR}^T + \mathbf{G}_{MQPR} \quad (3.16)$$

O algoritmo padrão para obter as componentes principais \mathbf{T}_{MQPR} e \mathbf{U}_{MQPR} é o método dos mínimos quadrados parciais iterativo não linear (MQPINL). Wold et al. (2001) descreve o algoritmo dos mínimos quadrados parciais iterativo não linear resumidamente em: determinar arbitrariamente o vetor \mathbf{u}_{MQPR} igual a uma coluna de \mathbf{Y}_{MQPR} para obter cada coluna dos pesos \mathbf{W}_{MQPR} dado por:

$$\mathbf{w}_{MQPR} = \frac{\mathbf{X}_{MQPR}^T \cdot \mathbf{u}_{MQPR}}{\mathbf{u}_{MQPR}^T \cdot \mathbf{u}_{MQPR}} \quad (3.17)$$

onde para obter a coluna de \mathbf{T}_{MQPR} utiliza-se:

$$\mathbf{t}_{MQPR} = \mathbf{X}_{MQPR} \cdot \mathbf{w}_{MQPR} \quad (3.18)$$

Calcula-se os pesos de \mathbf{Y}_{MQPR} em \mathbf{C}_{MQPR} , dado por:

$$\mathbf{c}_{MQPR} = \frac{\mathbf{Y}_{MQPR}^T \cdot \mathbf{t}_{MQPR}}{\mathbf{t}_{MQPR}^T \cdot \mathbf{t}_{MQPR}} \quad (3.19)$$

Atualiza-se os *scores* de \mathbf{Y}_{MQPR} em \mathbf{U}_{MQPR} , dado por:

$$\mathbf{u}_{MQPR} = \frac{\mathbf{Y}_{MQPR} \cdot \mathbf{c}_{MQPR}}{\mathbf{c}_{MQPR}^T \cdot \mathbf{c}_{MQPR}} \quad (3.20)$$

Realiza-se o teste de convergência de \mathbf{t}_{MQPR} , dado por (3.21), onde ε_{MQPR} é a constante predeterminada para o qual, não havendo convergência retorna-se para (3.17), caso contrário, aplica-se (3.21).

$$\frac{\|\mathbf{t}_{MQPR_{anterior}} - \mathbf{t}_{MQPR_{atual}}\|}{\|\mathbf{t}_{MQPR_{atual}}\|} \leq \varepsilon_{MQPR} \quad (3.21)$$

Em (3.21) remove-se a componente atual de \mathbf{X}_{MQPR} e \mathbf{Y}_{MQPR} , utilizando:

$$\mathbf{p}_{MQPR} = \frac{\mathbf{X}_{MQPR}^T \cdot \mathbf{t}_{MQPR}}{\mathbf{t}_{MQPR}^T \cdot \mathbf{t}_{MQPR}} \quad (3.22)$$

$$\mathbf{X}_{MQPR} = \mathbf{X}_{MQPR} - (\mathbf{t}_{MQPR} \cdot \mathbf{p}_{MQPR}^T) \quad (3.23)$$

$$\mathbf{Y}_{MQPR} = \mathbf{Y}_{MQPR} - (\mathbf{t}_{MQPR} \cdot \mathbf{c}_{MQPR}^T) \quad (3.24)$$

Repete-se o processo até que a quantidade de componentes em \mathbf{T}_{MQPR} e \mathbf{U}_{MQPR}

apresente erro quadrático médio mínimo desejado para \mathbf{F}_{MQPR} e \mathbf{G}_{MQPR} . O processo de validação cruzada, semelhante ao ilustrado na Figura 3.5, é aplicado para garantir que \mathbf{T}_{MQPR} e \mathbf{U}_{MQPR} sejam resumos de \mathbf{X}_{MQPR} e \mathbf{Y}_{MQPR} .

Após execução do algoritmo MQPINL, aplica-se o método **IVP** para identificar quais variáveis são mais significativas para o modelo, dado por (3.25). A contribuição da variável \mathbf{x}_{MQPR_j} para a construção da componente em $\mathbf{t}_{MQPR_\vartheta}$ é medida pelo peso $\mathbf{w}_{MQPR_\vartheta j}$. A redundância $Rd(\mathbf{Y}_{MQPR}, \mathbf{t}_{MQPR_\vartheta})$ mensura a contribuição da variável \mathbf{x}_{MQPR_j} para a construção de \mathbf{Y}_{MQPR} através das componentes $\mathbf{t}_{MQPR_\vartheta}$. Quanto maior a redundância maior é a importância da variável \mathbf{x}_{MQPR_j} no conjunto de variáveis em \mathbf{Y}_{MQPR} . As variáveis que possuem $IVP > 1$ são as mais importantes na construção de \mathbf{Y}_{MQPR} . As variáveis no intervalo $0,5 > IVP > 1$ são relevantes para o modelo e as variáveis que apresentem $IVP < 0,5$ são desprezíveis para o modelo (GALINDO-PRIEETO et al., 2014; TENENHAUS, 1998).

$$IVP_{\xi j} = \sqrt{\frac{\zeta}{Rd(\mathbf{Y}_{MQPR}, \mathbf{t}_{MQPR_\vartheta})} \cdot \sum_{\vartheta=1}^{\xi} Rd(\mathbf{Y}_{MQPR}, \mathbf{t}_{MQPR_\vartheta}) \cdot \mathbf{w}_{MQPR_\vartheta j}^2} \quad (3.25)$$

A expressão (3.26) informa que o somatório ao quadrado do valor IVP das variáveis de \mathbf{X}_{MQPR} , deve ser igual a quantidade de variáveis ζ .

$$\sum_{j=1}^{\zeta} IVP_{\xi j}^2 = \zeta \quad (3.26)$$

3.4 Considerações finais

Este capítulo apresentou o reconhecimento de padrões utilizando redes neurais artificiais, descrevendo resumidamente os principais conceitos para o desenvolvimento de modelo artificial capaz de reconhecer padrões aprendidos em treinamento supervisionado com o algoritmo de retropropagação do erro. É apresentado também o método para a otimização da topologia da rede neural e método para redução de variáveis. O reconhecimento de padrões será utilizado no próximo capítulo como método para a classificação dos solos.

CAPÍTULO 4

METODOLOGIA

Neste capítulo é apresentada a metodologia utilizada para a construção do dispositivo nas configurações com e sem dispersão de partículas, procedimentos de utilização do dispositivo, construção do banco de dados dos solos caracterizados, classificação dos solos utilizando rede neural artificial por reconhecimento de padrões e validação do método proposto.

4.1 Projeto do dispositivo proposto

As partículas do solo são formadas de acordo com os fatores característicos de cada região, proporcionando singularidades no agrupamento de partículas de argila, silte e areia, formando corpo único. A textura do solo é comumente obtida utilizando o ensaio de sedimentação, constituído de etapas separadas com operacionalidade manual, aplicando dispersão química e/ou mecânica na separação das partículas agregadas e medida da taxa de sedimentação. Neste trabalho é proposto o desenvolvimento de dispositivo para mensurar o comportamento das partículas em sedimentação, contendo duas configurações opcionais: i) com dispersão de partículas e ii) sem dispersão de partículas.

A Figura 4.1 ilustra os principais componentes do dispositivo em ambas configurações, onde a região na cor cinza indica a mudança para a configuração com e sem dispersão de partículas. São comuns às duas configurações: i) tampas removíveis inferior e superior, ii) compartimento de isolamento luminoso, iii) sistema receptor, iv) sistema emissor, v) câmara de sedimentação, vi) válvula proporcional, vii) câmara de retenção e viii) na configuração com dispersão, o dispositivo apresenta adicionalmente o motor de corrente contínua com hélice para dispersão mecânica das partículas (região na cor cinza da Figura 4.1).

As tampas removíveis inferior e superior permitem a vedação do dispositivo e a manutenção da limpeza. O compartimento de isolamento luminoso bloqueia os sistema receptor e emissor de qualquer fonte luminosa externa. O sistema emissor comporta as fontes luminosas do dispositivo e o sistema receptor recebe os feixes luminosos. A câmara de sedimentação é o compartimento onde as partículas são sedimentadas. A válvula proporcional controla a liberação das partículas da câmara de retenção para a câmara de sedimentação, sendo a câmara de retenção o compartimento onde as amostras do solo são inseridas para ensaio.

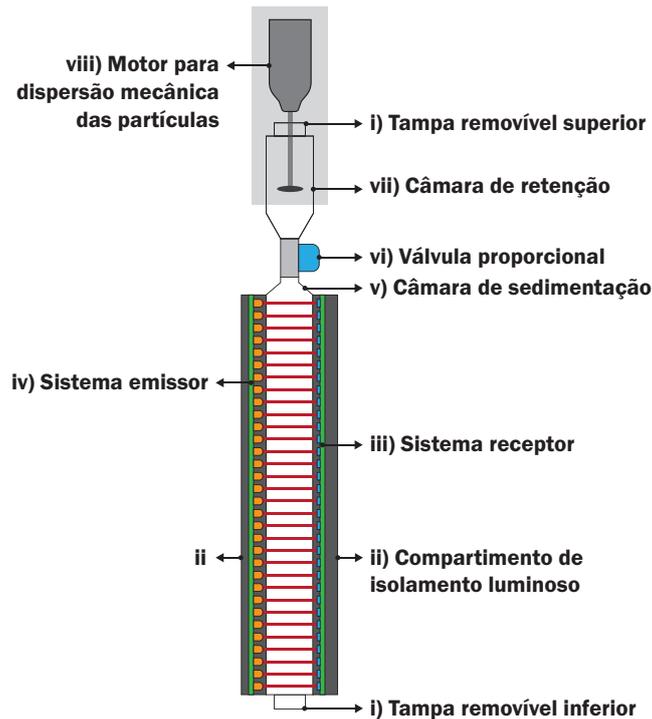


Figura 4.1 - Elementos que compõem o dispositivo proposto.

Levando em consideração a análise granulométrica das normas NBR 7181 e NBR 6457, a câmara de retenção e sedimentação são projetadas para comportarem 1000cm^3 de solução aquosa, simulando a proveta graduada. A câmara de retenção é análoga ao recipiente do dispersor motorizado de partículas, como descrito nas normas. Este trabalho adota a distribuição granulométrica para areia, silte e argila regulamentada pelo Departamento de Agricultura dos Estados Unidos (USDA), que também é adotada pela Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA).

4.1.1 Projeto mecânico

Para mensurar o comportamento de determinada amostra na câmara de sedimentação, é desenvolvido sistema para linearização das partículas. O sistema de linearização funciona com a retenção das partículas dispersas ou não na câmara de retenção, ilustrada na Figura 4.2(a), que após instante de tempo t as libera para a câmara de sedimentação, ilustrada na Figura 4.2(b). A válvula proporcional realiza a junção entre a câmara de retenção e a câmara de sedimentação, sendo o componente responsável pela retenção ou liberação do fluxo de partículas por força gravitacional. A Figura 4.2(c) ilustra a conexão entre estes três componentes.

A câmara de sedimentação ilustrada na Figura 4.2(b), possui aberturas em duas

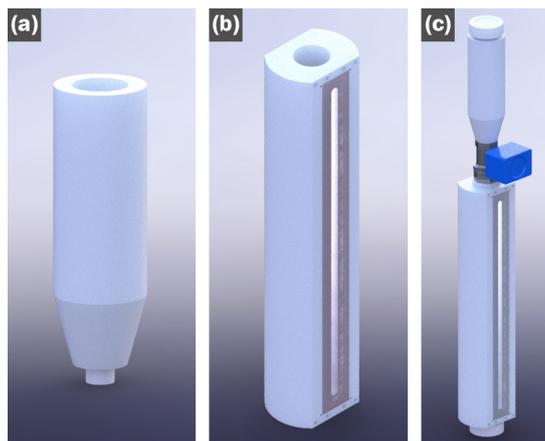


Figura 4.2 - Projeto mecânico do dispositivo proposto: (a) câmara de retenção, (b) câmara de sedimentação e (c) vista completa.

faces opostas para a passagem de luz, sendo o fluido isolado em cada face por vidros com alta transparência. A passagem da luz permite a aplicação do princípio da foto sedimentação, onde o sistema receptor e emissor são dispostos sob as faces opostas da câmara de sedimentação, como ilustrado na Figura 4.3(a). Para que a única fonte luminosa a atravessar a câmara de sedimentação seja o sistema emissor, é projetado compartimento para isolamento luminoso, ilustrado na Figura 4.3(b). Este compartimento é conectado sobre as faces opostas da câmara de sedimentação, isolando esta câmara de qualquer fonte luminosa externa.

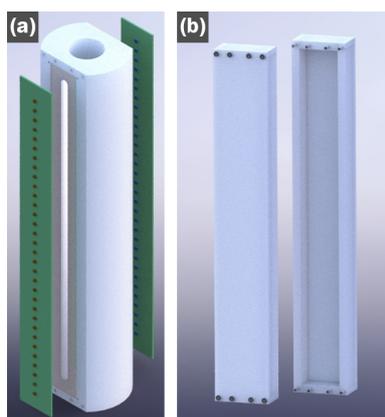


Figura 4.3 - Projeto mecânico do dispositivo proposto: (a) sistema emissor e receptor de luz e (b) compartimento de isolamento luminosa.

O dispositivo na configuração com dispersão de partículas tem motor de corrente contínua conectado na tampa superior, com hélices inseridas na câmara de retenção.

ção. A Figura 4.4(a) ilustra o dispositivo proposto na configuração sem dispersão de partículas, na Figura 4.4(b) a configuração com dispersão de partículas e na Figura 4.4(c) a vista explodida.

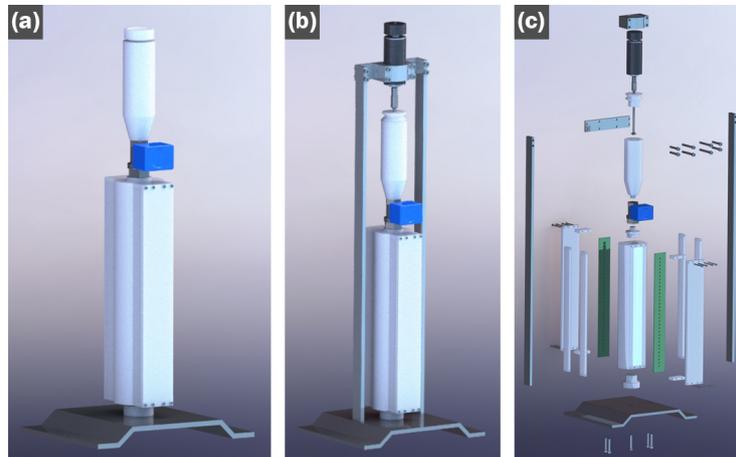


Figura 4.4 - Projeto mecânico do dispositivo proposto: (a) configuração sem dispersão de partículas, (b) configuração com dispersão de partículas e (c) vista explodida.

4.1.2 Projeto eletrônico

O projeto eletrônico é constituído por: i) sistema emissor, ii) sistema receptor e iii) sistema de controle e aquisição de dados. O sistema de controle e aquisição de dados (SCAD) atua no acionamento da válvula proporcional, motor, fontes luminosas do sistema emissor e na aquisição de dados do sistema receptor.

A Figura 4.5(a) ilustra o circuito eletrônico do sistema emissor contendo v diodos lasers e multiplexador MUX_{φ} , onde φ é a quantidade de multiplexadores necessária para acionar os v diodos lasers e ψ_a é a conexão a ser multiplexada. Cada multiplexador do sistema emissor conta com ψ_b conexões para acionamento da multiplexação. Os diodos lasers são acionados por multiplexação das conexões D_{ψ_b} entre o SCAD e o multiplexador, permitindo ao SCAD enviar o sinal da conexão LS_{ψ_a} aos canais de saída C_v do multiplexador, fornecendo tensão ao resistor R_2 ativando o transistor $n-p-n$, permitindo que a tensão V_s alimente o diodo laser em série com o resistor R_1 .

O circuito eletrônico do sistema receptor é ilustrado na Figura 4.5(b) contendo v fotodiodos conectados aos canais de saída C_v do multiplexador MUX_{φ} , onde por multiplexação as conexões E_{ψ_b} entre o SCAD e o multiplexador permitem a tensão

do resistor R_1 em paralelo com os fotodiodos ser obtida pelo SCAD mediante a conexão FT_{ψ_a} com o multiplexador.

A Figura 4.5(c) ilustra o circuito eletrônico do sistema de controle e aquisição de dados contendo o microcontrolador para acionamento digital e leitura analógica. O microcontrolador conta com ψ_b saídas digitais e ψ_a entradas analógicas. A Figura 4.5(d) ilustra o circuito eletrônico para acionamento da válvula proporcional (com tensão de alimentação V_W) e motor de corrente contínua (com tensão de alimentação V_M), onde as saídas digitais B_1 e B_2 acionam os módulos relé.

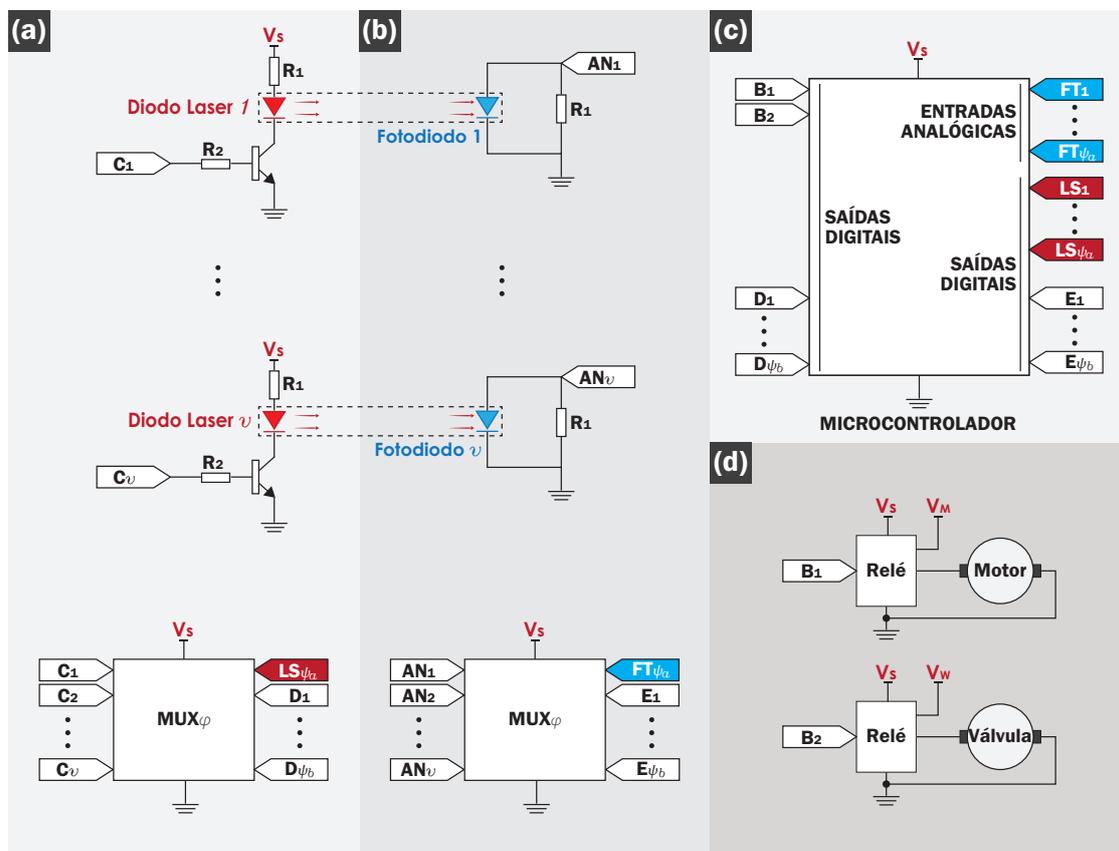


Figura 4.5 - Projeto eletrônico do dispositivo proposto: (a) sistema emissor, (b) sistema receptor, (c) sistema de controle e aquisição de dados e (d) circuito eletrônico para acionamento da válvula proporcional e motor.

O microcontrolador aciona o motor e/ou a válvula proporcional abrindo ou fechando-a para o preenchimento com água destilada na câmara de retenção e para liberação das partículas para a câmara de sedimentação. Após a liberação das partículas, o microcontrolador aciona em paralelo por multiplexação os diodos lasers e fotodiodos. Ao acionar o primeiro diodo laser, o primeiro fotodiodo também é acionado para

receber o feixe luminoso, formando assim o primeiro bloco emissão-recepção. No intervalo de tempo t o microcontrolador aciona todos os v blocos sucessivamente e recebe a leitura analógica da tensão nos terminais dos resistores em paralelo com os fotodiodos. A tensão é então convertida em sinal digital e enviada via comunicação serial ao computador onde os dados são armazenados no formato de matriz.

A quantidade de diodos lasers e fotodiodos depende do projeto mecânico e eletrônico, podendo ser reduzida ou ampliada de acordo com as dimensões da câmara de sedimentação, geometria dos lasers e fotodiodos empregados. A dimensão e a eletrônica proposta para o dispositivo permite que ele tenha alimentação elétrica suprida por pequenas baterias, garantindo a portabilidade do mesmo. A topologia do circuito idealizado objetiva ser a menor possível considerado a redução de custos financeiros.

4.2 Procedimento de utilização do dispositivo e construção do banco de dados

Os procedimentos para utilização do dispositivo são: i) acionar a válvula proporcional em modo abrir, ii) preencher o dispositivo com água destilada, iii) acionar a válvula proporcional em modo fechar, iv) adicionar amostra de solo na câmara de retenção, v) adicionar dispersante químico na câmara de retenção e vi) iniciar dispositivo para ensaio automático. Nesta configuração, o dispositivo inicia com repouso para dispersão química e na sequência aplica dispersão mecânica acionando o motor de corrente contínua. Após o processo de dispersão das partículas, o dispositivo aciona a válvula proporcional em modo abrir, onde as partículas por força gravitacional são inseridas na câmara de sedimentação e os sistemas emissor e receptor são acionados. Os procedimentos para a operacionalização do dispositivo na configuração sem dispersão das partículas segue o mesmo fluxo sem a utilização do motor de corrente contínua.

A metodologia proposta requer: i) banco de dados de solos e ii) dispositivo proposto. O banco de dados é formado por solo caracterizado por especialista e pela matriz construída utilizando o dispositivo, a partir dos sinais medidos nos fotodiodos. A luz transmitida I_0 pelo fotoemissor e a luz percebida I pelo foto receptor, como dado por (2.3), caracteriza o princípio da foto sedimentação, onde o decaimento da luz percebida é dada pela taxa de sedimentação das partículas. Este princípio é adotado para obter o comportamento da amostra do solo.

A Figura 4.6(a) ilustra a liberação das partículas disformes na câmara de reten-

ção para a câmara de sedimentação. O comportamento difuso das partículas em sedimentação é mensurado pelos fotodiodos. A Figura 4.6(b) ilustra o diâmetro d_L do feixe de luz monocromático (na cor vermelha) incidindo sobre a superfície do fotodiodo (na cor azul) com obstrução parcial dada pela concentração das partículas disformes (em tamanho ampliado para efeito didático), onde a luz que passa é proporcional a tensão elétrica fornecida no fotodiodo. Portanto, cada solo com suas características singulares no formato geométrico, diâmetro e densidade específica de suas partículas, produzem comportamento diferente a ser mensurado pelos fotodiodos do dispositivo.

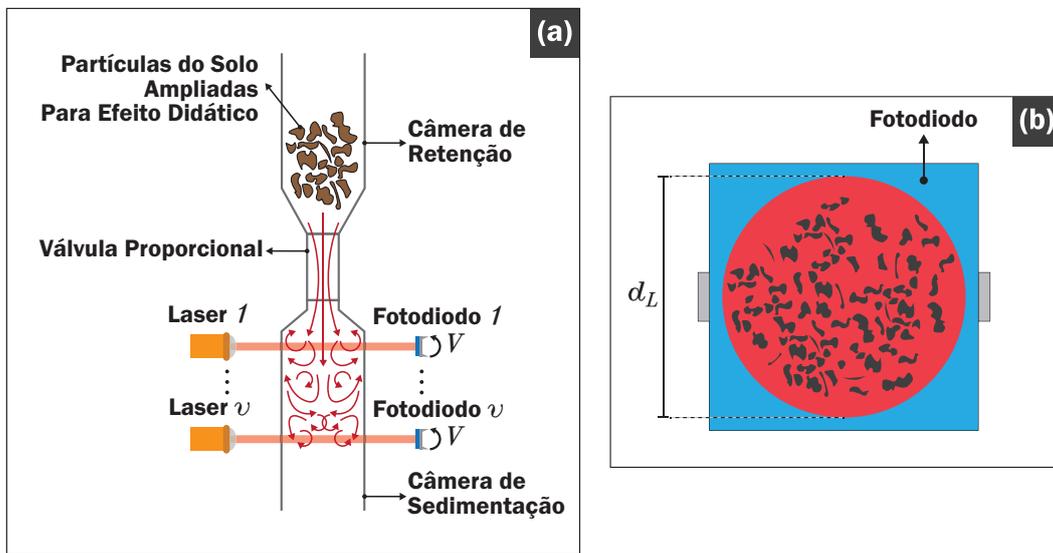


Figura 4.6 - Dispositivo proposto: (a) ilustração das partículas do solo sendo liberadas para sedimentação e (b) ilustração do feixe de luz monocromático incidindo sobre a superfície do fotodiodo.

Cada fotodiodo é um ponto de medição e fornece uma curva de tensão \times tempo. A combinação das medidas dos v fotodiodos forma a matriz de dados $\mathbf{M}_{\sigma(v \times z)}$, dada por (4.1). A matriz $\mathbf{M}_{\sigma(v \times z)}$ representa o comportamento da amostra do solo em análise.

$$\mathbf{M}_{\sigma(v \times z)} = \begin{bmatrix} m\sigma_{1,1} & m\sigma_{1,2} & m\sigma_{1,3} & m\sigma_{1,4} & \cdots & m\sigma_{1,z} \\ m\sigma_{2,1} & m\sigma_{2,2} & m\sigma_{2,3} & m\sigma_{2,4} & \cdots & m\sigma_{2,z} \\ m\sigma_{3,1} & m\sigma_{3,2} & m\sigma_{3,3} & m\sigma_{3,4} & \cdots & m\sigma_{3,z} \\ \vdots & \vdots & \vdots & \vdots & \ddots & \vdots \\ m\sigma_{v,1} & m\sigma_{v,2} & m\sigma_{v,3} & m\sigma_{v,4} & \cdots & m\sigma_{v,z} \end{bmatrix} \quad (4.1)$$

onde σ é o identificador da coletânea de ensaios, v é a quantidade de fotodiodo e z é a quantidade de medidas realizadas por fotodiodo. Neste trabalho, define-se como coletânea o conjunto de ensaios de K_k solos ensaiados uma vez. Deste modo, cada σ é matriz tridimensional que contém determinada coletânea de ensaios para cada K_k solos.

O projeto eletrônico não apresenta circuito elétrico para filtrar possíveis ruídos nos sinais gerados pelos fotodiodos, portanto, aplica-se na matriz $\mathbf{M}_{\sigma(v \times z)}$ filtro digital passas-baixas *Butterworth*, cujo o ganho G_{BW} é dado por (4.2), onde ρ é a ordem do filtro, ω é a frequência angular do sinal em radianos por segundo e ω_c é a frequência de corte. A matriz com os sinais filtrados é indicada por $\mathbf{M}_{F\sigma(v \times z)}$.

$$G_{BW_\rho}(\omega) = \frac{1}{\sqrt{1 + \left(\frac{\omega}{\omega_c}\right)^{2 \cdot \rho}}} \quad (4.2)$$

A Figura 4.7 ilustra o sistema proposto onde o dispositivo é utilizado para construir o banco de dados com solos classificados. Cada solo K_k caracterizado por especialista contém informações de classificação das ordens, subordens, grandes grupos e subgrupos entre outras propriedades tais como textura e teor de matéria orgânica. As amostras dos K_k solos são submetidas aos ensaios no dispositivo com o intuito de construir a matriz tridimensional $\mathbf{M}_{F\sigma(v \times z \times k)}$.

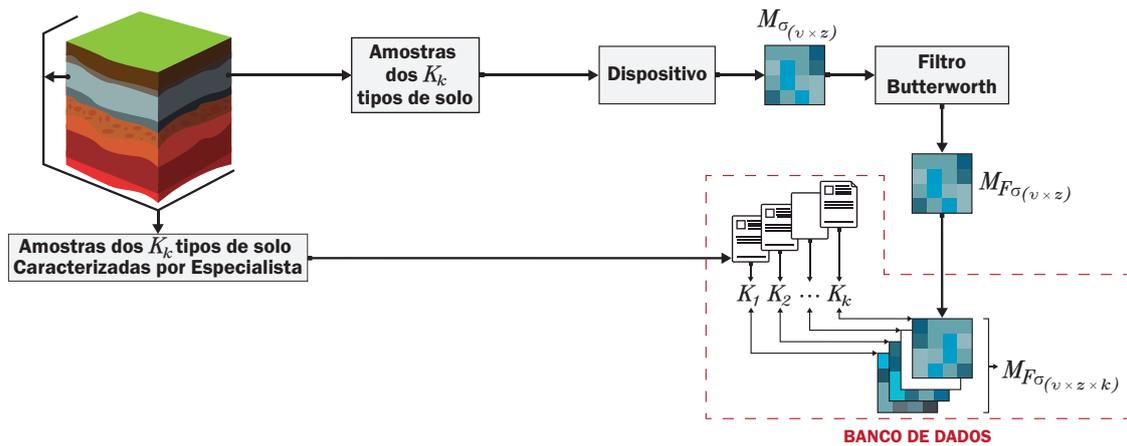


Figura 4.7 - Construção do banco de dados.

Segundo Santos et al. (2006), existem 871 subgrupos de solos classificados no Brasil, sendo 161 argissolos, 91 cambissolos, 30 chernossolos, 45 espodossolos, 111 gleissolos,

87 latossolos, 30 luvisolos, 73 neossolos, 44 nitossolos, 39 organossolos, 55 planossolos, 68 plintossolos e 37 vertissolos. Portanto, o banco de dados considerando todos os subgrupos de solos brasileiros é dado por K_k com $k \in \mathbb{N}^* | k = 1, 2, \dots, 871$.

De posse do banco de dados pode se realizar a caracterização do solo utilizando o dispositivo proposto mediante o reconhecimento de padrões. Para cada novo solo caracterizado por especialista e adicionado ao banco de dados, o mesmo deve ser ensaiado com o dispositivo, fornecendo a matriz de dados. Não é a proposta deste trabalho construir o banco de dados completo. A proposta é apresentar a metodologia e o dispositivo para a classificação automática do solo. No entanto, uma vez construído o banco de dados com todos os 871 subgrupos de solos brasileiros e outros, toda e qualquer amostra ensaiada terá um representante no banco de dados e assim será possível identificá-la por reconhecimento de padrões.

4.3 Rede neural artificial aplicada à reconhecimento de padrões

A rede neural artificial Perceptron de múltiplas camadas (MLP) é utilizada como sistema de reconhecimento de padrões. A Figura 4.8 ilustra a MLP onde o número de neurônios na camada de entrada é dado pela quantidade de fotodiodos v e o número de neurônios na camada de saída é dado pela quantidade de linhas q da matriz binária tridimensional $\mathbf{S}_{(q \times 1 \times k)}$, onde a quantidade de linhas q é igual a $k_{\text{máximo}}$. O vetor $\mathbf{S}_{(q \times 1 \times k)}$ é a representação de cada tipo de solo analisado e caracterizado pelo especialista dado por k variando de $1 \leq k \leq 871$. Para tanto, cada solo é representado por um neurônio q na camada de saída, e este recebe valor igual a 1 quando $q = k$ e 0 quando $q \neq k$. No treinamento da rede, para cada k solos haverá n ciclos de treinamento.

O treinamento da MLP é realizado utilizando o algoritmo retropropagação do erro (*backpropagation*), onde os dados utilizados para o aprendizado são normalizados para evitar a saturação dos neurônios durante o treinamento da MLP. A matriz $\mathbf{M}_{F\sigma_{(v \times z \times k)}}$ é normalizada com seus elementos ajustados no intervalo $-1 \leq \check{m}_{F\sigma_{(v,z,k)}} \leq 1$. A normalização *Minmax* dada por (4.3) é adotada, onde $m_{F\sigma_{(v \times z \times k)}}$ é o valor a ser modificado, $m_{F\sigma_{(v_{\min}, z_{\min}, k_{\min})}}$ é o menor valor e $m_{F\sigma_{(v_{\max}, z_{\max}, k_{\max})}}$ é o maior valor dos elementos em $\mathbf{M}_{F\sigma_{(v \times z \times k)}}$. Os valores $\check{m}_{F\sigma_{(v,z,k)}}$ correspondem aos valores normalizados e os limites mínimo e máximo são dados por $d_1 = -1$ e $d_2 = 1$.

$$\check{m}_{F\sigma_{(v,z,k)}} = \frac{\left[m_{F\sigma_{(v,z,k)}} - m_{F\sigma_{(v_{\min}, z_{\min}, k_{\min})}} \right] \cdot (d_2 - d_1)}{m_{F\sigma_{(v_{\max}, z_{\max}, k_{\max})}} - m_{F\sigma_{(v_{\min}, z_{\min}, k_{\min})}}} + d_1 \quad (4.3)$$

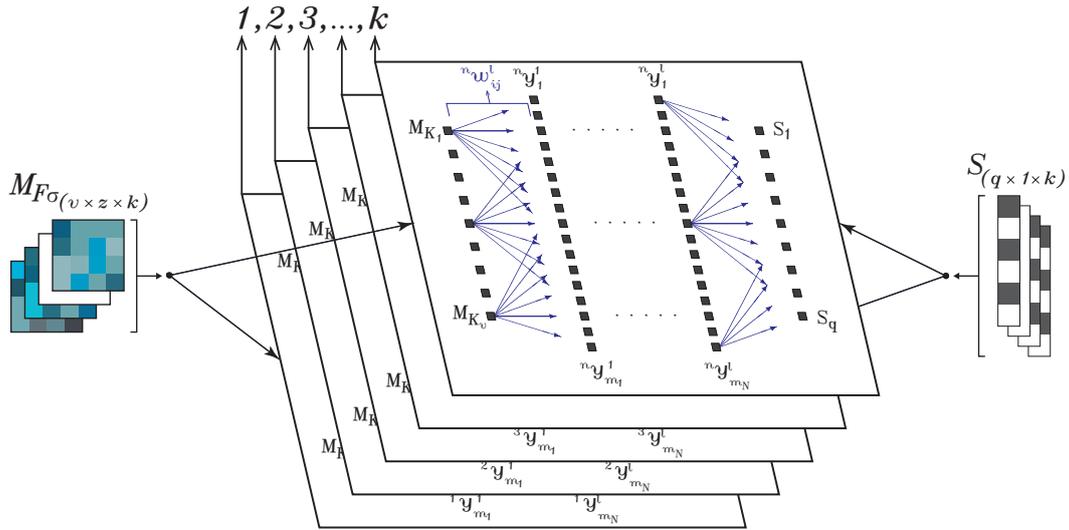


Figura 4.8 - Ilustração da rede neural artificial proposta.

A matriz normalizada $\check{M}_{\sigma(v \times z \times k)}$ é aplicada à ferramenta estatística de validação cruzada para garantir a generalização da MLP. A Figura 4.9 ilustra a aplicação da ferramenta, onde a matriz $\check{M}_{\sigma(v \times z \times k)}$ é dividida aleatoriamente em matriz para estimação $A_{1(v \times z \times k)}$, matriz de validação $A_{2(v \times z \times k)}$ e matriz de teste $B_{(v \times z \times k)}$. Os pesos sinápticos da MLP são ajustados utilizando a matriz de dados $A_{1(v \times z \times k)}$, e validados com a matriz $A_{2(v \times z \times k)}$. Após o treinamento, a MLP é testada com a matriz $B_{(v \times z \times k)}$ para garantir a generalização.

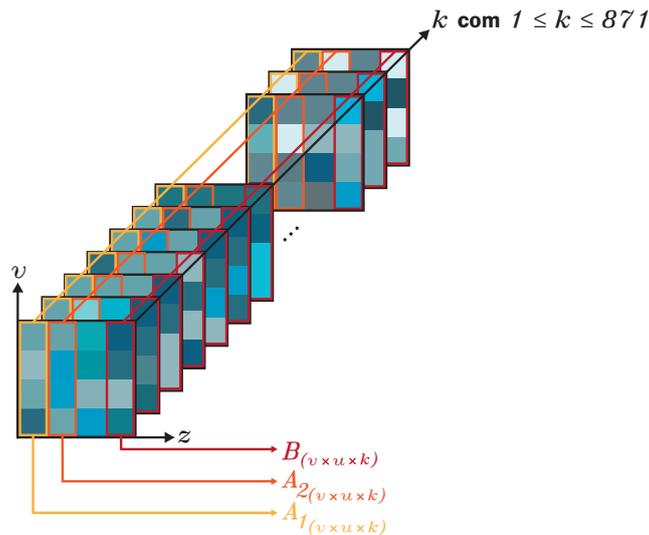


Figura 4.9 - Validação cruzada onde a matriz $\check{M}_{\sigma(v \times z \times k)}$ é dividida aleatoriamente em $A_{1(v \times z \times k)}$, $A_{2(v \times z \times k)}$ e $B_{(v \times z \times k)}$.

O algoritmo de retropropagação do erro, é executado durante ϕ ciclos ou até que a matriz de pesos sinápticos seja ajustada para que a saída atual da rede menos o erro desejado, dado por (3.7), seja aproximadamente *zero*. Visando otimizar o desempenho da rede, o método heurístico algoritmo genético é aplicado para encontrar as melhores topologias da MLP.

A Figura 4.10 ilustra o fluxo de operação do algoritmo genético onde a população contém indivíduos com dois genes dado em (4.4), onde a_{GA} é a quantidade de camadas ocultas e b_{GA} a quantidade de neurônios em cada camada oculta. A população inicial contém h_{GA} indivíduos gerados com os genes recebendo valores inteiros aleatórios. Devido a natureza estocástica da validação cruzada e inicialização dos pesos da MLP, cada indivíduo é simulado k_{GA} vezes, sendo a função de avaliação dada pela média e desvio padrão do erro para as k_{GA} interações.

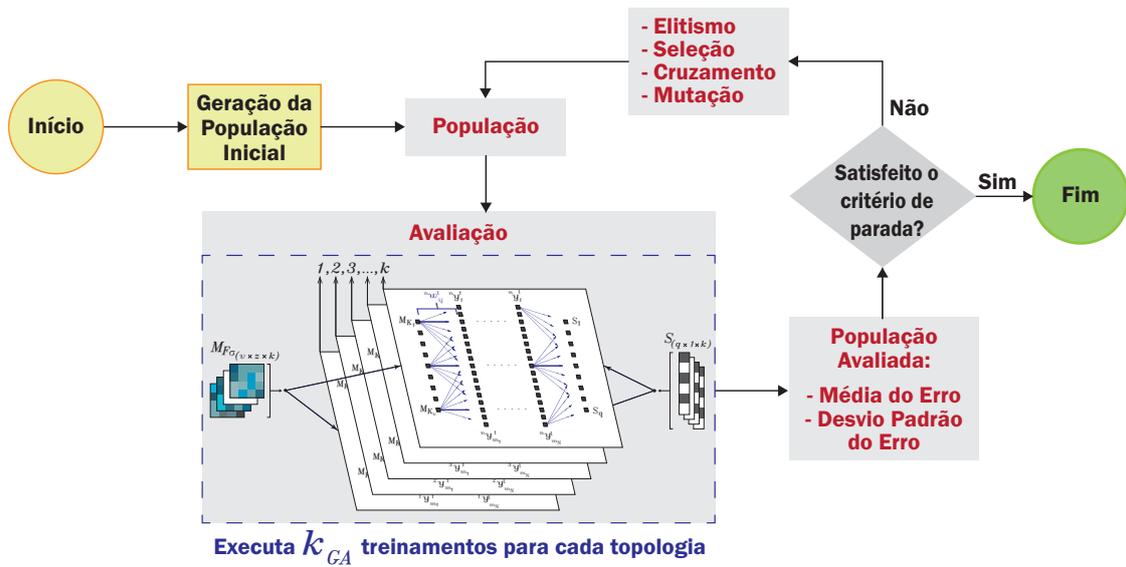


Figura 4.10 - Algoritmo genético aplicado na topologia da rede neural artificial proposta.

$$c_{GA} = [a_{GA} \ b_{GA}] \quad (4.4)$$

Após definir a topologia da rede e ajustar os pesos sinápticos, o sistema de reconhecimento de padrões estará apto para identificar os solos presentes no banco de dados. Para tanto, valida-se o sistema de reconhecimento de padrões aplicando amostras de solos caracterizados, classificados e que não fazem partes das amostras utilizadas no treinamento.

4.4 Validação do dispositivo e sistema de reconhecimento de padrões

A **eficácia** e **eficiência** do dispositivo proposto é verificada na etapa de validação. A verificação da eficácia qualifica o dispositivo atestando se o mesmo alcança o objetivo para o qual foi projetado. Para mensurar a porcentagem de acerto no reconhecimento dos solos, faz-se uso da verificação da eficiência do sistema de reconhecimento de padrões em classificar os solos.

A eficácia do dispositivo proposto é dada submetendo diferentes solos para ensaio e aferindo se os dados produzidos pelo aparato são diferentes para cada solo e/ou se submetendo o mesmo solo sucessivamente os dados fornecidos apresentam o mesmo padrão (mesmos valores), onde será utilizado a expressão do erro quadrático médio para medir o desvio entre os ensaios do mesmo tipo de solo. Portanto, cada K_k solo é submetido a ρ ensaios gerando σ matrizes $\mathbf{M}_{F\sigma(v \times z \times k)}$, com σ variando de 1, 2, 3, ..., ρ .

A eficiência do método proposto é quantificada aferindo percentual de identificação da MLP em reconhecer os solos caracterizados. A eficiência do sistema proposto para solos não caracterizados é medida utilizando o ensaio de descaracterização de amostras, onde determinada amostra caracterizada deve ser modificada misturando-a com outra amostra desconhecida.

Depois de validado, o método proposto está apto a identificar novas amostras submetidas a ensaio. A Figura 4.11 ilustra a utilização do dispositivo após validação, onde a nova amostra do solo é submetida ao ensaio no dispositivo, o qual produz a matriz $\mathbf{M}_{F\sigma(v,z)}$. A matriz produzida é normalizada e então aplicada a entrada da MLP, onde os pesos sinápticos ajustados e o padrão binário a ser reconhecido na saída da rede é dado pelo banco de dados.

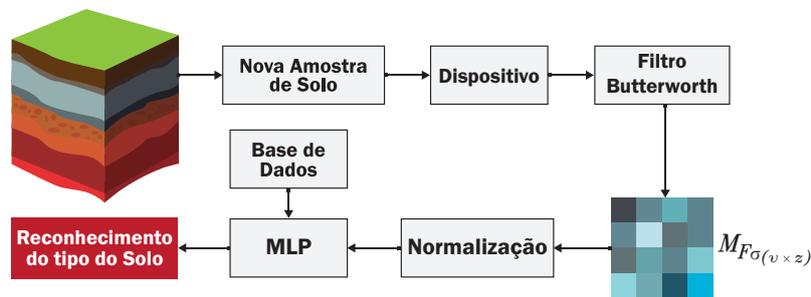


Figura 4.11 - Identificação de novas amostras.

4.4.1 Análise de sensibilidade na projeção de variáveis

Aplica-se a análise de sensibilidade utilizando o método de importância das variáveis de projeção (IVP) nos mínimos quadrados parciais para regressão (MQPR) para encontrar quais v fotodiodos são mais significativos, apresentando maior influência na caracterização do comportamento do solo em sedimentação. Para obter as componentes principais do MQPR, é adotado o algoritmo dos mínimos quadrados parciais iterativo não linear (MQPINL), onde a transposta da matriz $\mathbf{M}_{F\sigma(v \times z \times k)}$ é dada como preditora e $\mathbf{S}_{(q \times 1 \times k)}$ como resposta. De posse das componentes principais, o método de importância das variáveis de projeção (IVP) é utilizado para encontrar quais fotodiodos apresentam $IVP > 1$.

4.5 Considerações finais

Este capítulo apresentou a metodologia utilizada para a construção do dispositivo capaz de gerar dados que caracterizem o comportamento dos solos em sedimentação a serem reconhecidos por rede neural artificial Perceptrons de múltiplas camadas. O próximo capítulo exibirá os resultados obtidos em ensaio para os solos selecionados, bem como os resultados do reconhecimento de padrões.

CAPÍTULO 5

RESULTADOS

Neste capítulo são apresentados os resultados empregando a metodologia abordada no Capítulo 4. Este capítulo está dividido em seis partes: i) desenvolvimento do aparato, ii) banco de dados, iii) reconhecimento de padrões, iv) validação do dispositivo e sistema de reconhecimento de padrões, v) análise de sensibilidade na projeção de variáveis e vi) comentários.

5.1 Desenvolvimento do dispositivo

O dispositivo proposto é capaz de fornecer dados para análise do solo utilizando banco de dados de solos caracterizados por especialista em conjunto com a rede neural artificial. Este dispositivo apresenta-se como diferencial dos fotos sedimentômetros apresentados por Buah-Bassuah et al. (1998) e Caron et al. (1996) por conter vários pontos de medição ao longo do recipiente ao qual as partículas são dispostas para sedimentação e por linearizar a liberação das partículas para sedimentação. O projeto mecânico e eletrônico, bem como a metodologia para identificação do solo é de carácter investigativo.

5.1.1 Projeto mecânico

O dispositivo proposto é apresentado na Figura 5.1(a) na configuração com dispersão de partículas e na Figura 5.1(b) na configuração sem dispersão de partículas. Na Tabela 5.1 são dispostas as medidas dos principais componentes do aparato em ambas configurações. A câmara de sedimentação, câmara de retenção e câmara escura foram desenvolvidas em material plástico poliacetal, devido à fácil maleabilidade de operação no processo de usinagem das peças e custo inferior se comparada a outros materiais metálicos.

Tabela 5.1 - Principais medidas dos componentes do dispositivo.

Componentes	Medidas [mm]		
	Largura	Altura	Profundidade
Câmara de Sedimentação	100	75	450
Câmara de Retenção	65	65	100
Câmara Escura 1º Face	70	40	450
Câmara Escura 2º Face	70	40	450
Sistema Emissor	50	420	4
Sistema Receptor	50	420	4



Figura 5.1 - Dispositivo proposto na configuração: (a) com dispersão de partículas e (b) sem dispersão de partículas.

5.1.2 Projeto eletrônico

O projeto eletrônico do dispositivo desenvolvido com seus componentes e respectivos nomes e valores são ilustrados na Figura 5.2. A Figura 5.2(a) ilustra o projeto do circuito eletrônico do sistema emissor contendo 32 diodos lasers de $5mW$ com comprimento de onda de $650nm$ e dois multiplexadores CD74HC4067 de dezesseis canais cada. A Figura 5.2(b) ilustra o projeto do circuito eletrônico do sistema receptor contendo 32 fotodiodos BPW34 e dois multiplexadores CD74HC4067 de dezesseis canais cada. A Figura 5.2(c) ilustra as conexões empregadas pelo microcontrolador Arduino MEGA 2560 R3 que adquire os dados e controlar o processo, através de doze saídas digitais e duas entradas analógicas. A Figura 5.2(d) ilustra as conexões dos dois relés de atraso FC-32 responsáveis pelo acionamento do motor CC de $100V$ e da válvula esférica proporcional motorizada de $12V$.

As dimensões adotadas no projeto mecânico, bem como a geometria dos componentes eletrônicos adotados, permitiram que o projeto eletrônico pudesse contar com a quantidade máxima de 35 pontos de foto medição (35 fotodiodos). No entanto, adotou-se a quantidade de 32 devido aos multiplexadores comercialmente disponíveis comportarem dezesseis canais.

Os sistemas emissor e receptor desenvolvidos são apresentados na Figura 5.3(a) e

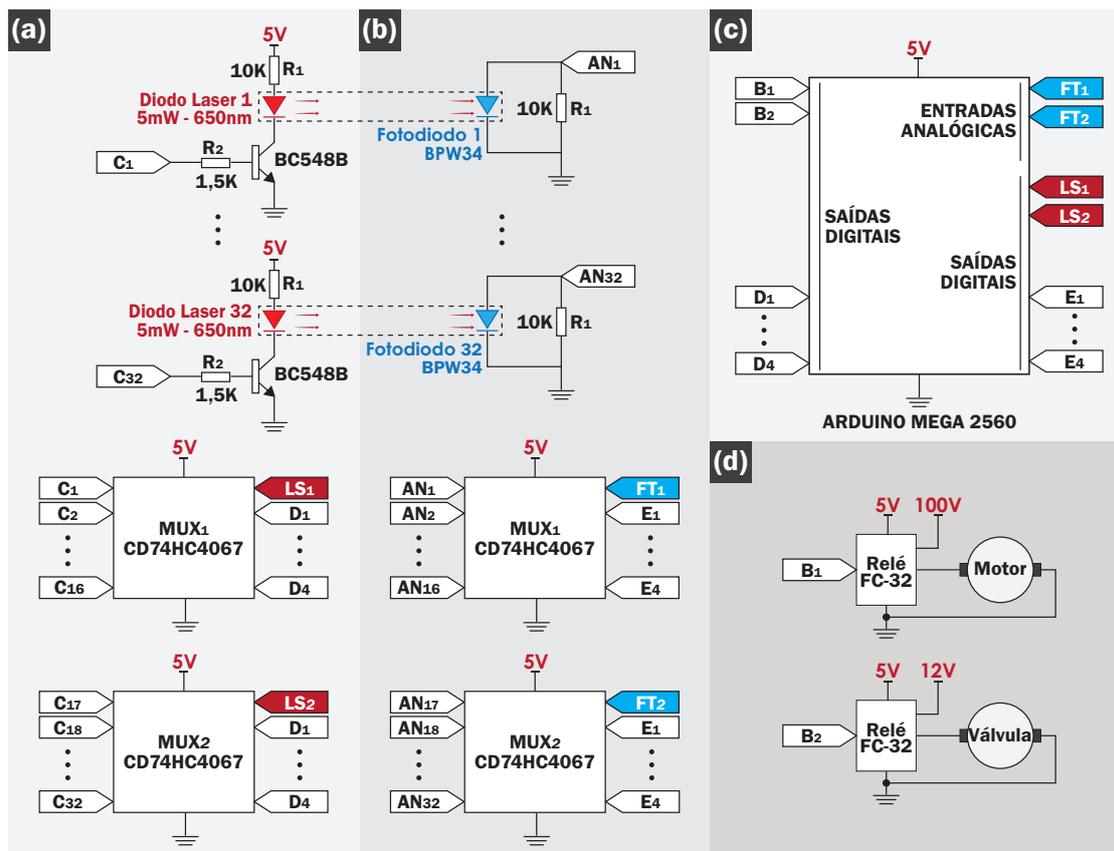


Figura 5.2 - Projeto eletrônico do dispositivo desenvolvido: (a) sistema emissor, (b) sistema receptor, (c) sistema de controle e aquisição de dados e (d) circuito eletrônico para acionamento da válvula proporcional e motor.

Figura 5.3(b). A Figura 5.3(c) apresenta o módulo laser de baixa potência utilizado e o colimador acrílico. O fotodiodo BPW34, da fabricante *Vishy*, é apresentado na Figura 5.3(d) e sua sensibilidade espectral relativa é apresentada na Figura 5.4. Os fotodiodos operaram em taxa de eficiência próximo de 60% para os lasers utilizados. A tensão produzida pelo fotodiodo BPW34 é dada por $V_{min} = 0V$, para completa obstrução do feixe de luz monocromática e $V_{max} \cong 0,52V$ para nenhuma obstrução.

A Figura 5.5(a) apresenta a válvula esférica proporcional motorizada utilizada da fabricante HDCL, com 20mm de abertura e acionamento em 12V. A Figura 5.5(b) exibe o motor de corrente contínua adotado, com tensão de funcionamento em 100V e potência de 500W (12000rpm), comumente utilizado em processos de comando numérico computadorizado (CNC).

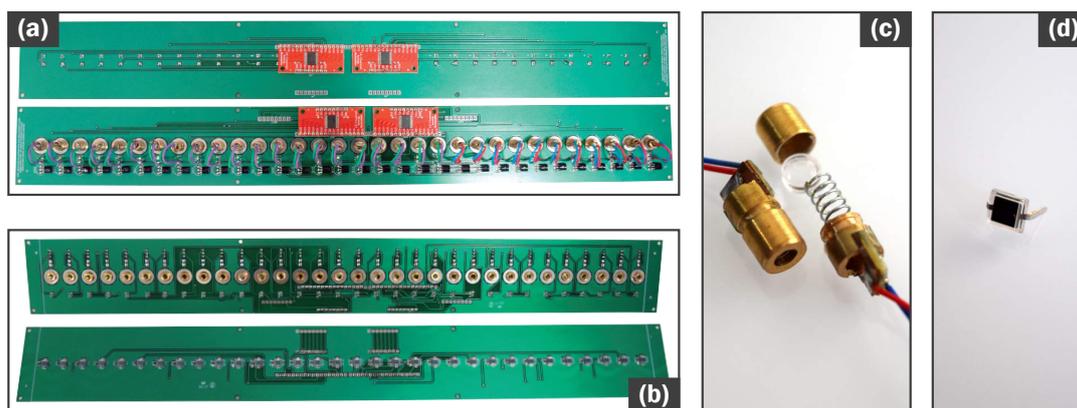


Figura 5.3 - Sistemas emissor e receptor: (a) vista superior, (b) vista inferior, (c) laser de $5mW$ e (d) fotodiodo BPW34.

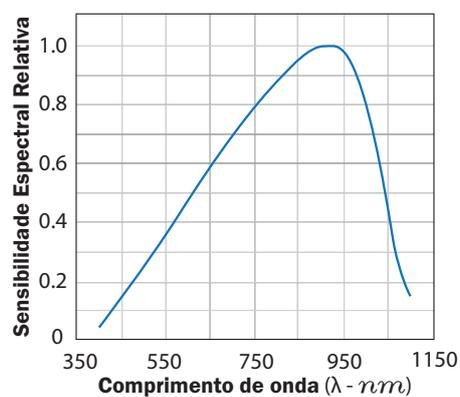


Figura 5.4 - Sensibilidade espectral relativa \times comprimento de onda.

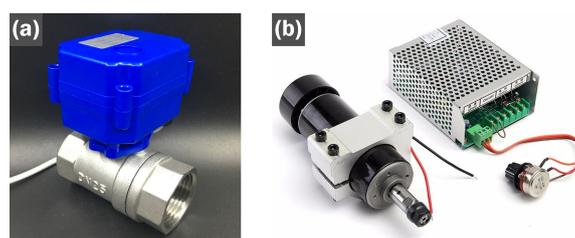


Figura 5.5 - Dispositivos utilizados: (a) válvula esférica motorizada e (b) motor de corrente contínua.

5.2 Preparação e geração do banco de dados

Os solos caracterizados que compõem o banco de dados deste trabalho, dispostos na Tabela 5.2, foram classificados e tiveram textura e demais parâmetros identificados

pelos professores e discentes da Escola de Agronomia da Universidade Federal de Goiás (PACHECO, 2017). Os solos da Tabela 5.2 dispõem a classificação, textura e percentual de matéria orgânica dos solos.

Tabela 5.2 - Classificação, textura e matéria orgânica dos solos utilizados.

Classificação dos Solos	Textura (%)			Matéria Orgânica (%)	Localização da Coleta dos Solos
	Areia	Silte	Argila		
1 Gleissolo Melânico Distrófico	59	9	32	3,2	16°36'18.53"S 49°16'55.41"W
2 Latossolo Vermelho Ácrico	45	11	44	2,3	16°35'49.0"S 49°16'59.1"W
3 Latossolo Vermelho Amarelo Distrófico Petroplúntico	68	19	13	0,6	16°50'57.49"S 49°20'54.78"W
4 Latossolo Vermelho Distrófico	39	11	50	2,5	16°30'35.36"S 49°17'26.92"W
5 Luvisolo Háptico	54	9	37	1,3	08°43'53.2"S 38°51'16.7"W
6 Neossolo Flúvico Ta Distrófico	34	50	11	2,9	17°22'37.67"S 53°05'38.80"W
7 Neossolo Quartzarênico Órtico	87	4	9	0,9	17°00'31.3"S 50°37'06.5"W

Para realizar os ensaios com o dispositivo em ambas configurações, para cada solo da Tabela 5.2, coletou-se 5g de amostra e diluiu-a com bastão de vidro em 100ml de água destilada. Após diluída a amostra é introduzida na câmara de retenção e ao fim de cada ensaio o dispositivo foi higienizado internamente com água filtrada para impedir que partículas do solo ensaiado permanecessem na câmara de sedimentação e retenção, descaracterizando o próximo ensaio.

Foram realizados dois tipos de testes no dispositivo: i) na configuração com dispersão de partículas Figura 5.1(a) e ii) na configuração sem dispersão de partículas Figura 5.1(b). Os resultados para a configuração com dispersão de partículas, devido a utilização de laser de baixa potência e com fraca amplificação da luz monocromática pela lente acrílica, foram insatisfatórios. As amostras com alto teor de argila e matéria orgânica após serem submetidas a dispersão química com 2,5g de carbonato de sódio anidro + 45,7g de hexametáfosfato de sódio e dispersão motorizada a 12000rpm, elevaram a turbidez da solução aquosa não permitindo a passagem do feixe de luz, mesmo após período de 24 horas em sedimentação. Com isto, observa-se que para a implementação da configuração com dispersão de partículas é necessário adotar lasers de alta potência. No entanto, os resultados obtidos com a configuração sem dispersão de partículas, foram satisfatórios e utilizados para gerar o banco de dados do trabalho proposto.

De posse dos sete solos classificados da Tabela 5.2, dividiu-se cada tipo de solo

em cinco porções a serem analisadas pelo dispositivo. O microcontrolador realizou leituras em cada fotodiodo a cada 0,03125 segundos, onde a cada 1 segundo os sinais de todos os 32 fotodiodos são obtidos. As leituras para cada ensaio foram realizadas durante 25 minutos (1500 segundos), gerando a matriz $\mathbf{M}_{\sigma(32 \times 1500)}$ dada por (4.1), para cada solo. Os dados/sinais obtidos foram uniformizados aplicando o filtro digital *Butterworth* de segunda ordem, com $0,5\pi rad$ de frequência angular e $-3dB$ de frequência de corte, gerando a matriz $\mathbf{M}_{F\sigma(32 \times 1500)}$.

Destaca-se a nomenclatura da matriz tridimensional $\mathbf{M}_{F\sigma(v \times z \times k)}$, onde σ é o conjunto de diferentes solos ensaiados única vez formando uma coletânea, v é a quantidade de fotodiodos, z é a quantidade de medidas realizadas por fotodiodo e k é o identificador do solo. Para aferir a eficácia do dispositivo realizou-se cinco coletâneas, utilizando para cada ensaio 5g da amostra de cada K_k solo da Tabela 5.2, onde $k \in \mathbb{N}^* | k = 1, 2, \dots, 7$. As coletâneas dada por $M_{F\sigma}$ são ensaios de cada tipo de solo formando a matriz tridimensional $\mathbf{M}_{F\sigma(v \times z \times k)}$, onde $\sigma \in \mathbb{N}^* | \sigma = 1, 2, \dots, 5$.

Desta forma, pode-se definir as matrizes tridimensionais para: $\sigma = 1$ tem-se $\mathbf{M}_{F1(32 \times 1500 \times 7)}$, a qual defini a primeira coletânea que contém um ensaio de cada solo. Assim respectivamente, para $\sigma = 2$, $\sigma = 3$, $\sigma = 4$ e $\sigma = 5$ tem-se $\mathbf{M}_{F2(32 \times 1500 \times 7)}$, $\mathbf{M}_{F3(32 \times 1500 \times 7)}$, $\mathbf{M}_{F4(32 \times 1500 \times 7)}$ e $\mathbf{M}_{F5(32 \times 1500 \times 7)}$. Assim, são realizadas cinco ensaios para cada solo, estando cada ensaio em uma coletânea, sendo sete tipos de solos, realiza-se neste trabalho 35 ensaios no total de 5 coletâneas. O intuito das coletâneas é a construção do banco de dados. Para cada novo solo futuramente ensaiado deve ser realizado cinco ensaios e cada ensaio deve ser colocado em uma coletânea.

A Figura 5.6 apresenta a tensão obtida **sem** e **com** a aplicação do filtro digital, para o Gleissolo Melânico Distrófico, identificado por $k = 1$. A Figura 5.6(a), Figura 5.6(b) e Figura 5.6(c) apresentam os dados obtidos pelos fotodiodos $v = 4$, $v = 8$ e $v = 32$ durante leitura de 1500 segundos, da coletânea $\sigma = 1$. Os dados filtrados para os mesmos fotodiodos são apresentados na Figura 5.6(d), Figura 5.6(e) e Figura 5.6(f).

5.2.1 Gleissolo Melânico Distrófico

A Figura 5.7 apresenta a amostra do Gleissolo Melânico Distrófico identificado por $k = 1$, onde na Figura 5.8(a) apresenta a tensão produzida no fotodiodo $v = 1$, para cinco ensaios realizados com o Gleissolo Melânico Distrófico. A Figura 5.8(b), Figura 5.8(c), Figura 5.8(d), Figura 5.8(e) e Figura 5.8(f), apresentam respectivamente as tensões produzidas nos fotodiodos $v = 6$, $v = 12$, $v = 18$, $v = 24$ e $v = 30$ para cada ensaio.

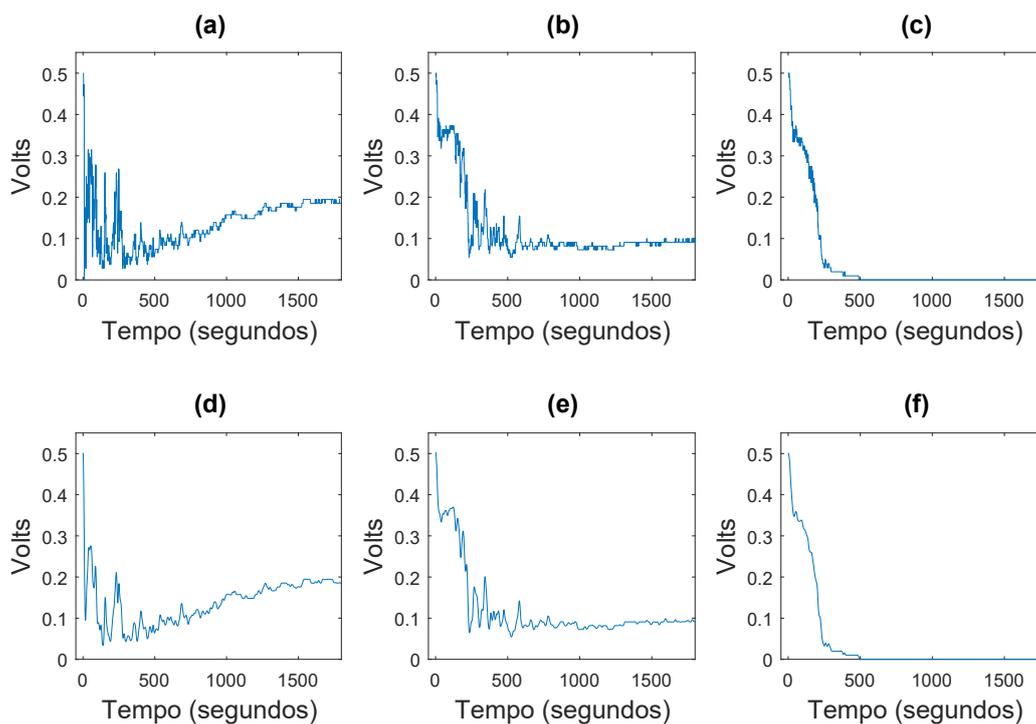


Figura 5.6 - Tensão produzida **sem** e **com** aplicação de filtro digital.



Figura 5.7 - Gleissolo Melânico Distrófico.

Observa-se na Figura 5.8 que as curvas de tensão produzida pelos fotodiodos nos cinco ensaios para o Gleissolo Melânico Distrófico, apresentaram variações na leitura de um fotodiodo para outro, como desejado. Observa-se faixa de valores com desvios próximos a $0,1V$, apresentando o padrão a ser identificado pelas redes neurais artificiais. Para medir a eficácia do dispositivo, utilizou-se a expressão do erro quadrático médio para comparar o desvio entre os dados obtidos no primeiro ensaio e os dados obtidos nos demais ensaios. A Tabela 5.3 dispõe os desvios, onde observa-se valores na ordem de 10^{-2} , indicando a heterogeneidade das partículas no que se refere ao tamanho, formato geométrico e densidade.

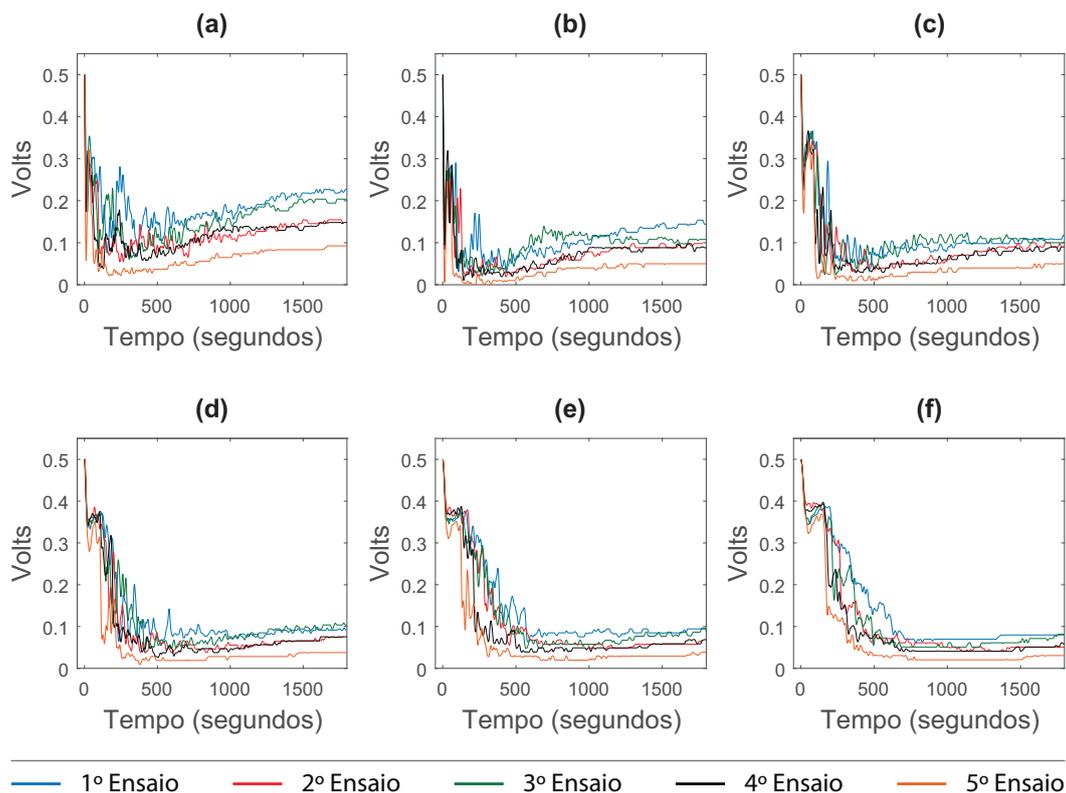


Figura 5.8 - Tensão produzida para cinco ensaios com amostras do Gleissolo Melânico Distrófico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Tabela 5.3 - Desvio entre os ensaios para o Gleissolo Melânico Distrófico.

Fotodiodos	$v = 1$	$v = 6$	$v = 12$	$v = 18$	$v = 24$	$v = 30$
2° Ensaio	0,0053	0,0023	0,0013	0,0017	0,0014	0,0023
3° Ensaio	0,0028	0,0012	0,0013	0,0017	0,0011	0,0016
4° Ensaio	0,0057	0,0020	0,0024	0,0021	0,005	0,0045
5° Ensaio	0,0152	0,0056	0,0061	0,0073	0,0099	0,0094

5.2.2 Latossolo Vermelho Ácrico

A Figura 5.9 apresenta a amostra do Latossolo Vermelho Ácrico identificado por $k = 2$. A Figura 5.10(a) apresenta a tensão produzida no fotodiodo $v = 1$, para cinco ensaios realizados com o Latossolo Vermelho Ácrico. A Figura 5.10(b), Figura 5.10(c), Figura 5.10(d), Figura 5.10(e) e Figura 5.10(f), apresentam respectivamente as tensões produzidas nos fotodiodos $v = 6$, $v = 12$, $v = 18$, $v = 24$ e $v = 30$ para cada ensaio.

Destaca-se que o fotodiodo $v = 1$ é o primeiro a ter o feixe de luz interceptado pelas partículas liberadas pela válvula proporcional e o fotodiodo $v = 32$, o último.



Figura 5.9 - Latossolo Vermelho Ácrico.

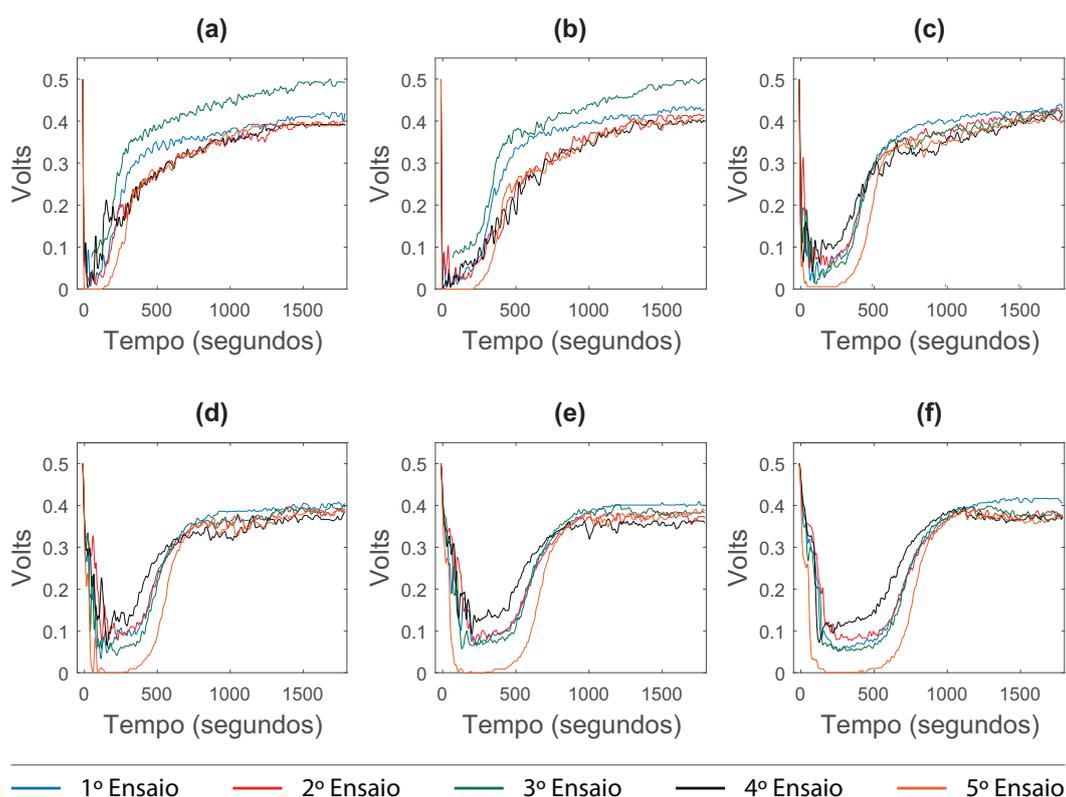


Figura 5.10 - Tensão produzida para cinco ensaios com amostras do Latossolo Vermelho Ácrico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Ao observar as tensões produzidas pelos fotodiodos $v = 1$ e $v = 30$ para o Latossolo Vermelho Ácrico na Figura 5.10(a) e Figura 5.10(f), nota-se o atraso temporal na sedimentação de algumas partículas, as quais sedimentaram nos primeiros 500 segundos. Após a sedimentação destas partículas, observa-se que outras partículas não sedimentaram, permanecem com valores entre $0,35V$ a $0,4V$ indicando turbidez com baixa concentração de partículas.

A Tabela 5.4 dispõe os desvios nos valores das curvas de tensão, onde observa-se valores na ordem de 10^{-2} , indicando a eficácia do dispositivo em mensurar comportamentos semelhantes para o mesmo tipo de solo.

Tabela 5.4 - Desvio entre os ensaios para o Latossolo Vermelho Ácrico.

Fotodiodos	$v = 1$	$v = 6$	$v = 12$	$v = 18$	$v = 24$	$v = 30$
Ensaio 2	0,0014	0,0031	0,0011	0,0012	0,0009	0,0007
Ensaio 3	0,0004	0,001	0,0009	0,0006	0,0008	0,0003
Ensaio 4	0,0021	0,0037	0,0027	0,0022	0,002	0,0021
Ensaio 5	0,0023	0,0036	0,0042	0,0049	0,0062	0,0063

5.2.3 Latossolo Vermelho Amarelo Distrófico Petroplúntico

A Figura 5.11 apresenta a amostra do Latossolo Vermelho Amarelo Distrófico Petroplúntico identificado por $k = 3$, onde na Figura 5.12(a) apresenta a tensão produzida no fotodiodo $v = 1$, para cinco ensaios realizados com o Latossolo Vermelho Amarelo Distrófico Petroplúntico. A Figura 5.12(b), Figura 5.12(c), Figura 5.12(d), Figura 5.12(e) e Figura 5.12(f), apresentam respectivamente as tensões produzidas nos fotodiodos $v = 6$, $v = 12$, $v = 18$, $v = 24$ e $v = 30$ para cada ensaio.



Figura 5.11 - Latossolo Vermelho Amarelo Distrófico Petroplúntico.

As curvas de tensão obtidas para o Latossolo Vermelho Amarelo Distrófico Petroplúntico, apresentadas na Figura 5.12, indicam aumento de turbidez nos primeiros 500 segundos e redução de turbidez no tempo seguinte. A maior concentração de partículas observada está na faixa de aproximadamente 0,1V a 0,2V, e após 500 segundos as curvas de tensão geradas nos cinco ensaios, apresentam lento crescimento, indicando lenta sedimentação das partículas. Os desvios entre as curvas de tensão do primeiro ensaio e as demais são dispostos na Tabela 5.5, onde observa-se valores na ordem de 10^{-2} .

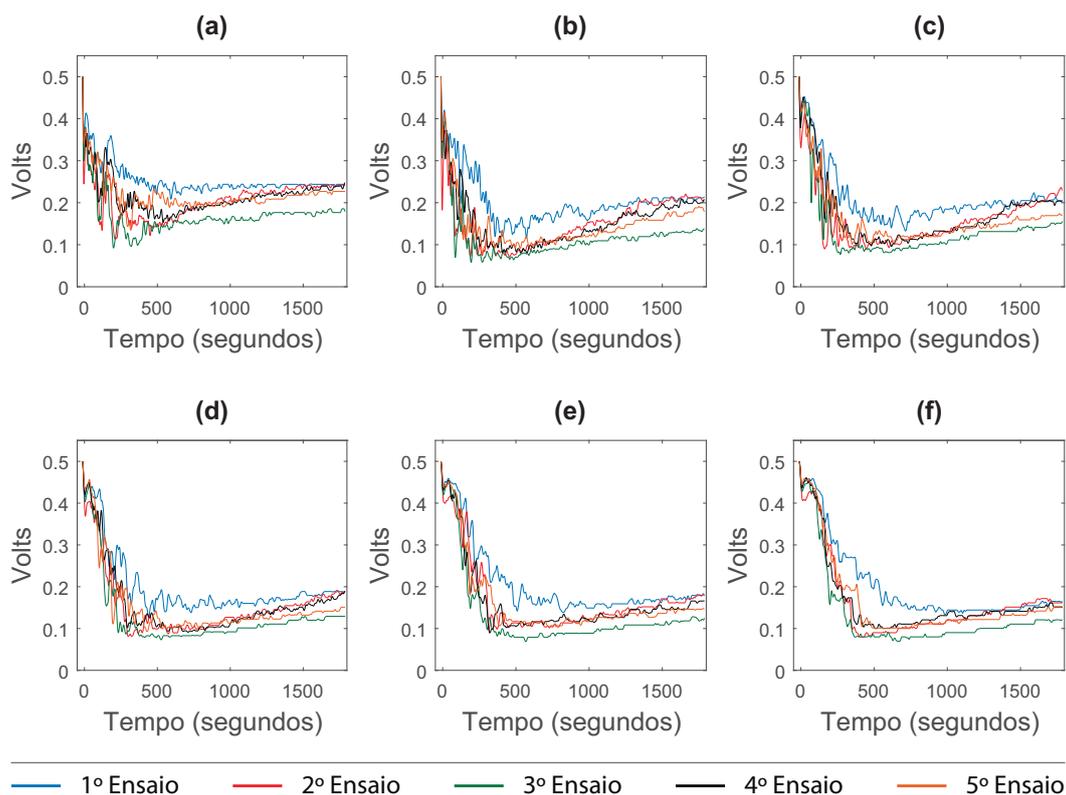


Figura 5.12 - Tensão produzida para cinco ensaios com amostras do Latossolo Vermelho Amarelo Distrófico Petroplúntico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Tabela 5.5 - Desvio entre os ensaios para o Latossolo Vermelho Amarelo Distrófico Petroplúntico.

Fotodiodos	$v = 1$	$v = 6$	$v = 12$	$v = 18$	$v = 24$	$v = 30$
Ensaio 2	0,0048	0,0071	0,0052	0,0045	0,0041	0,0047
Ensaio 3	0,0088	0,0098	0,0078	0,0080	0,0081	0,0079
Ensaio 4	0,0022	0,0044	0,0031	0,0029	0,0038	0,0035
Ensaio 5	0,0018	0,0048	0,0031	0,0032	0,0031	0,0028

5.2.4 Latossolo Vermelho Distrófico

A Figura 5.13 apresenta a amostra do Latossolo Vermelho Distrófico identificado por $k = 4$. A Figura 5.14(a) apresenta a tensão produzida no fotodiodo $v = 1$, para cinco ensaios realizados com o Latossolo Vermelho Distrófico. A Figura 5.14(b), Figura 5.14(c), Figura 5.14(d), Figura 5.14(e) e Figura 5.14(f), apresentam respectivamente as tensões produzidas nos fotodiodos $v = 6$, $v = 12$, $v = 18$, $v = 24$ e $v = 30$ para cada ensaio.

O Latossolo Vermelho Distrófico é solo com alto teor de argila. As curvas de tensão



Figura 5.13 - Latossolo Vermelho Distrófico.

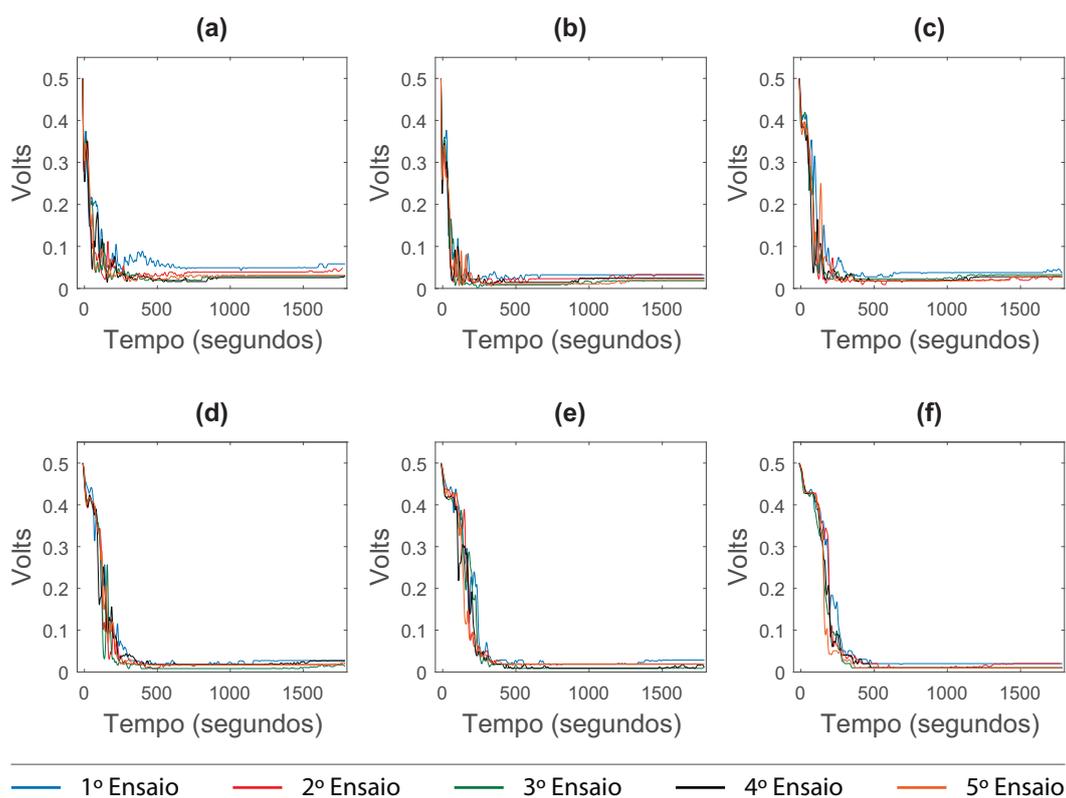


Figura 5.14 - Tensão produzida para cinco ensaios com amostras do Latossolo Vermelho Distrófico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

para os cinco ensaios apresentadas na Figura 5.14, indicam aumento acentuado na turbidez durante os primeiros 400 segundos. Após 400 segundos, as curvas de tensão estabilizam-se na faixa de aproximadamente $0,03V$ a $0,08V$, indicando alta concentração de partículas.

A Tabela 5.6 dispõe os desvios apresentado pelas curvas de tensão entre os ensaios do Latossolo Vermelho Distrófico. Observa-se valores menores que 10^{-2} para os desvios entre as curvas de tensão.

Tabela 5.6 - Desvio entre os ensaios para o Latossolo Vermelho Distrófico.

Fotodiodos	$v = 1$	$v = 6$	$v = 12$	$v = 18$	$v = 24$	$v = 30$
Ensaio 2	0,0011	0,0004207	0,0009	0,0005	0,001	0,0004
Ensaio 3	0,0013	0,000391	0,0011	0,0011	0,0006	0,0009
Ensaio 4	0,0011	0,0004791	0,0017	0,0007	0,0011	0,0006
Ensaio 5	0,0015	0,0005583	0,0011	0,0005	0,0015	0,0018

5.2.5 Luvissole Háplico

A Figura 5.15 apresenta a amostra do Luvissole Háplico, identificado por $k = 5$, onde na Figura 5.16(a) apresenta a tensão produzida no fotodiodo $v = 1$, para cinco ensaios realizados com o Luvissole Háplico. A Figura 5.16(b), Figura 5.16(c), Figura 5.16(d), Figura 5.16(e) e Figura 5.16(f), apresentam respectivamente as tensões produzidas nos fotodiodos $v = 6$, $v = 12$, $v = 18$, $v = 24$ e $v = 30$ para cada ensaio.



Figura 5.15 - Luvissole Háplico.

Semelhante ao Latossolo Vermelho Distrófico, as curvas de tensão apresentadas na Figura 5.16 para o Luvissole Háplico indicam redução de tensão acentuada durante os 100 primeiros segundos. Observa-se que o Luvissole Háplico, como disposto na Tabela 5.2, possui aproximadamente 33% menos teor de argila que o Latossolo Vermelho Distrófico. Por ter menor teor de argila, a partir de 500 segundos, as curvas de tensão começam a apresentar leve crescimento indicando lenta sedimentação das partículas.

A Tabela 5.7 dispõe os desvios apresentado pelas curvas de tensão entre os ensaios, estabelecendo a primeira coletânea como referência para mensurar o desvio em relação as demais coletâneas do Luvissole Háplico. Para este solo, observa-se valores de desvio na ordem de 10^{-3} .

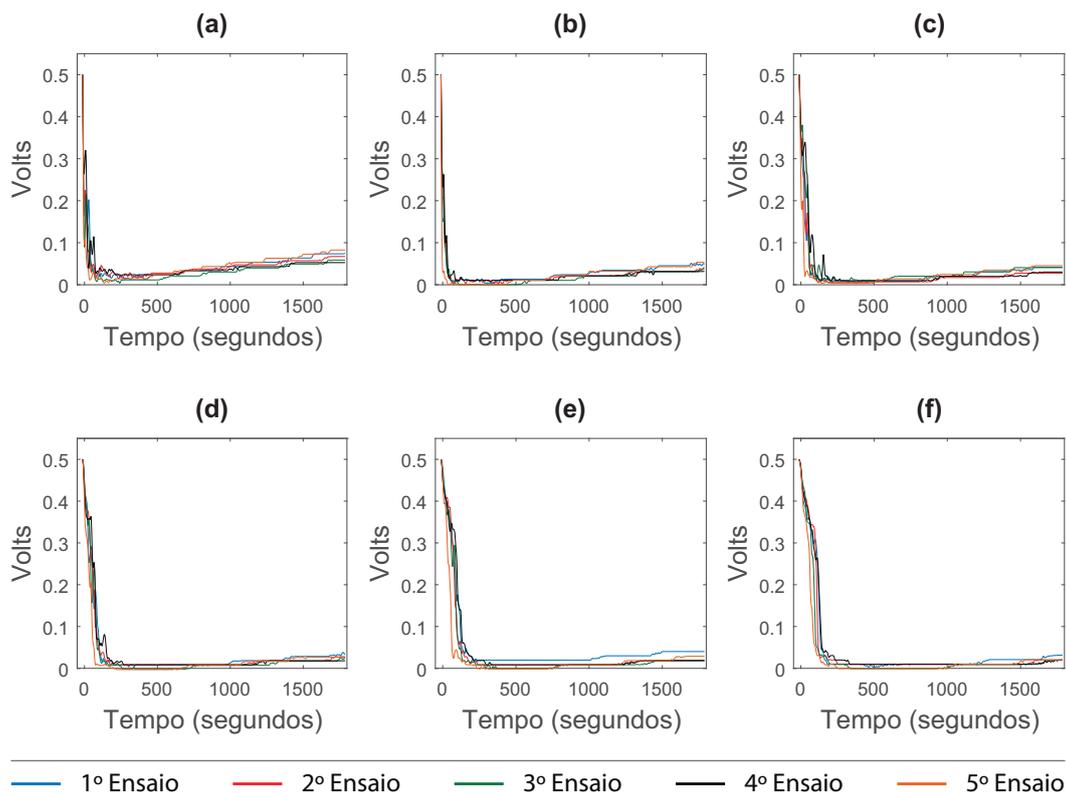


Figura 5.16 - Tensão produzida para cinco ensaios com amostras do Luvissole Háplico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Tabela 5.7 - Desvio entre os ensaios para o Luvissole Háplico.

Fotodiodos	$v = 1$	$v = 6$	$v = 12$	$v = 18$	$v = 24$	$v = 30$
Ensaio 2	0,0001728	0,0000669	0,0001263	0,0001648	0,0002	0,0003
Ensaio 3	0,0001711	0,0001329	0,0002291	0,0003478	0,0002	0,001
Ensaio 4	0,0004597	0,000165	0,0005491	0,000341	0,0003	0,0001
Ensaio 5	0,0004781	0,0002745	0,0007422	0,0008375	0,0018	0,0021

5.2.6 Neossolo Flúvico Ta Distrófico

A Figura 5.17 apresenta a amostra do Neossolo Flúvico Ta Distrófico identificado por $k = 6$. A Figura 5.18(a) apresenta a tensão produzida no fotodiodo $v = 1$, para cinco ensaios realizados com o Neossolo Flúvico Ta Distrófico. A Figura 5.16(b), Figura 5.18(c), Figura 5.18(d), Figura 5.18(e) e Figura 5.18(f), apresentam respectivamente as tensões produzidas nos fotodiodos $v = 6$, $v = 12$, $v = 18$, $v = 24$ e $v = 30$ para cada ensaio.

Os Neossolos são solos jovens com relação ao tempo de exposição as forças do intemperismo, apresentando baixo teor de argila. As curvas de tensão apresentadas na



Figura 5.17 - Neossolo Flúvico Ta Distrófico.

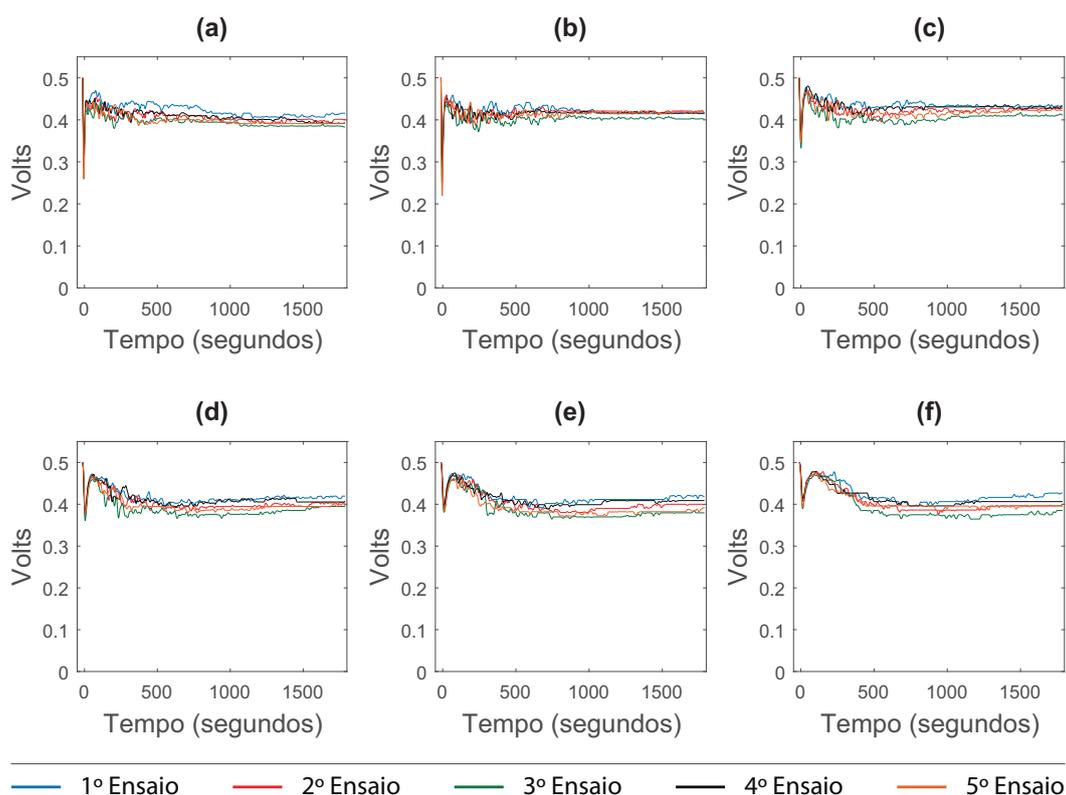


Figura 5.18 - Tensão produzida para cinco ensaios com amostras do Neossolo Flúvico Ta Distrófico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Figura 5.18, indicam redução acentuada de tensão nos primeiros 50 segundos seguida por aumento e estabilização, ocorrendo novamente a redução até aproximadamente 500 segundos. Após os primeiros 500 segundos, as partículas estabilizam-se em aproximadamente $0,4V$, indicando baixa concentração de partículas. Na Figura 5.18(e) é observado que nos primeiros 100 segundos, todas as cinco curvas praticamente não apresentam desvio. No entanto, nos instantes seguintes as curvas começam a apresentar pequenos desvios, em aproximadamente $0,4V$ a $0,44V$, podendo ser indicação

de que as partículas menores deste tipo de solo apresentam maior heterogeneidade no tamanho.

A Tabela 5.8 dispõe os desvios apresentado pelas curvas de tensão entre os ensaios para o Neossolo Flúvico Ta Distrófico. Observa-se valores de desvio na ordem de 10^{-3} .

Tabela 5.8 - Desvio entre o primeiro ensaio comparado com os demais para o Neossolo Flúvico Ta Distrófico.

Fotodiodos	$v = 1$	$v = 6$	$v = 12$	$v = 18$	$v = 24$	$v = 30$
Ensaio 2	0,0001892	0,000127	0,0000745	0,0002	0,0001068	0,0003305
Ensaio 3	0,0007359	0,0005134	0,0005454	0,001	0,000515	0,000946
Ensaio 4	0,0001555	0,0001736	0,0001103	0,0001	0,0000774	0,0001179
Ensaio 5	0,0004859	0,0002577	0,0004692	0,0004	0,0003074	0,0003001

5.2.7 Neossolo Quartzarênico Órtico

A Figura 5.19 apresenta a amostra do Neossolo Quartzarênico Órtico identificado por $k = 7$, onde na Figura 5.20(a) apresenta a tensão produzida no fotodiodo $v = 1$, para cinco ensaios realizados com o Neossolo Quartzarênico Órtico. A Figura 5.20(b), Figura 5.20(c), Figura 5.20(d), Figura 5.20(e) e Figura 5.20(f), apresentam respectivamente as tensões produzidas nos fotodiodos $v = 6$, $v = 12$, $v = 18$, $v = 24$ e $v = 30$ para cada ensaio.



Figura 5.19 - Neossolo Quartzarênico Órtico.

Semelhante ao Neossolo Flúvico Ta Distrófico, as curvas de tensão apresentadas na Figura 5.20 para o Neossolo Quartzarênico Órtico indicam estabilização das partículas próximo a $0,4V$. A Tabela 5.8 dispõe os desvios apresentado pelas curvas de tensão entre os ensaios para o Neossolo Flúvico Ta Distrófico. Para este solo, observa-se valores de desvio na ordem de 10^{-3} .

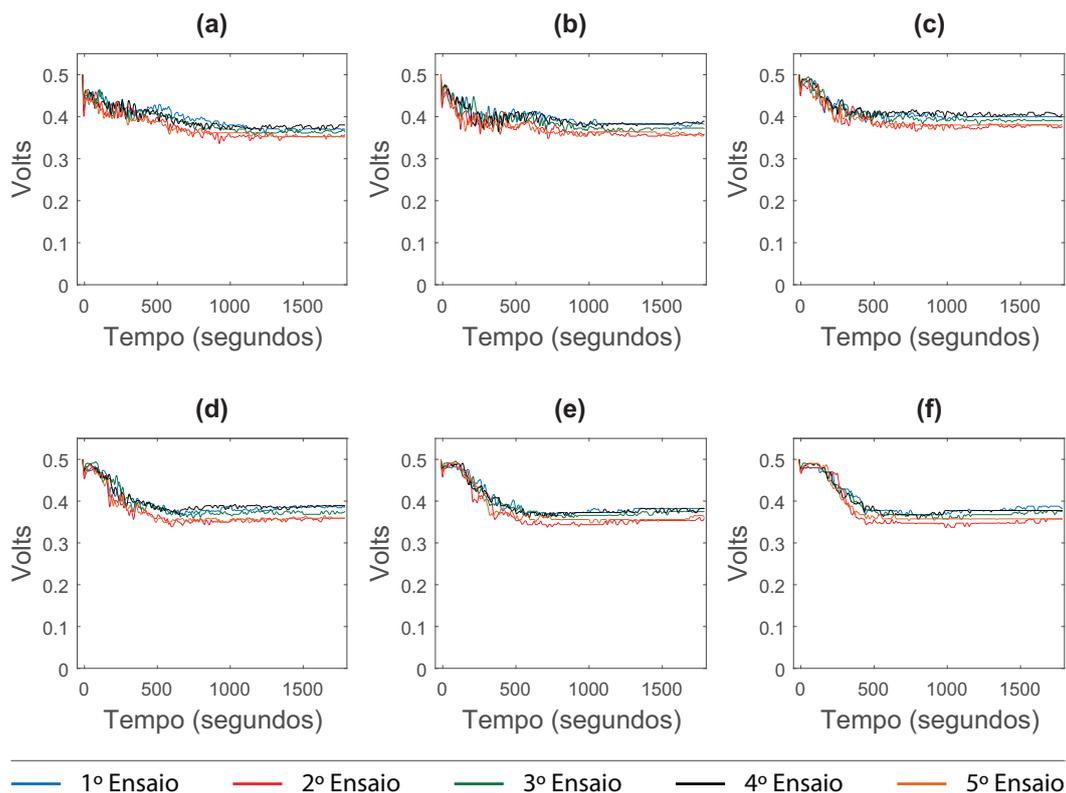


Figura 5.20 - Tensão produzida para cinco ensaios com amostras do Neossolo Quartzarênico Órtico no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Tabela 5.9 - Desvio entre os ensaios para o Neossolo Quartzarênico Órtico.

Fotodiodos	$v = 1$	$v = 6$	$v = 12$	$v = 18$	$v = 24$	$v = 30$
Ensaio 2	0,0006237	0,0006501	0,0005384	0,0005645	0,0007152	0,000743
Ensaio 3	0,0001505	0,0002662	0,000163	0,0001535	0,0003165	0,000101
Ensaio 4	0,0001449	0,0001166	0,000085	0,0001083	0,0000642	0,000059
Ensaio 5	0,0006181	0,0006783	0,0004763	0,0005373	0,0008273	0,0003654

5.3 Aplicação do reconhecimento de padrões

Os padrões observados nas curvas de tensão para cada tipo de solo é indicativo de características singulares de cada solo durante o processo de sedimentação gravitacional. Os sistemas de reconhecimento de padrões conseguem perceber características não percebida por seres humanos, embora como os seres vivos, necessite de aprendizagem. Entende-se que devido à heterogeneidade das partículas de cada tipo de solo, seria necessário mais que cinco ensaios com cada tipo de solo, de forma a garantir o aprendizado do sistema de reconhecimento de padrão com generalização. No entanto, devido as limitações de tempo e recursos, optou-se por cinco ensaios

para cada tipo de solo tendo em vista somente a apresentação do dispositivo e da metodologia adotada.

As matrizes $\mathbf{M}_{F1(32 \times 1500 \times 7)}$, $\mathbf{M}_{F2(32 \times 1500 \times 7)}$, $\mathbf{M}_{F3(32 \times 1500 \times 7)}$ e $\mathbf{M}_{F4(32 \times 1500 \times 7)}$, que são as coletâneas M_{F1} , M_{F2} , M_{F3} e M_{F4} contendo os ensaios de cada solo da Tabela 5.2, foram utilizadas para realizar o treinamento da rede neural artificial Perceptron de múltiplas camadas (MLP), onde a quantidade de neurônios na camada de entrada são 32 e a quantidade de neurônios na camada de saída são sete. Na saída da rede como resposta desejada, aplicou-se a matriz binária tridimensional $\mathbf{S}_{(q \times 1 \times k)}$, onde q é a quantidade de neurônios dada por $q = k$, e k é o identificador do solo. Dado que $k \in \mathbb{N}^* | k = 1, 2, \dots, 7$, tem-se $\mathbf{S}_{(7 \times 1 \times 7)}$. Portanto, cada tipo de solo é representado por um neurônio, que apresenta valor um para acertos e zero para erros. Observa-se que a matriz $\mathbf{M}_{F5(32 \times 1500 \times 7)}$ não foi utilizada para treinamento, pois será utilizada posteriormente para validação do reconhecimento de padrão.

Utiliza-se o algoritmo genético para encontrar a melhor topologia da rede neural. O algoritmo genético utilizado tem como parâmetros: i) dez números de indivíduos na população, ii) 100 gerações, iii) seleção por torneio, iv) operador de cruzamento simples, v) operador de mutação não uniforme, vi) taxa de cruzamento de 40% em todas gerações e vii) taxa de mutação de 20% em todas gerações.

Os resultados obtidos pelo algoritmo genético são disposto na Tabela 5.10. Os genes de cada indivíduo foram limitados no espaço de busca de valores inteiros no intervalo [1, 25]. Desta forma, o número máximo de camadas escondidas e de neurônios em cada camada foi de 25. Cada indivíduo de cada geração foi testado no treinamento com algoritmo de retropropagação do erro $k_{GA} = 20$ vezes, onde a média e desvio padrão do erro (entre a resposta desejada e a resposta gerada) da MLP, após treinamento para vinte execuções, é dada como função de avaliação.

Tabela 5.10 - Topologias encontradas pelo algoritmo genético.

Indivíduos	Genes		Média do Erro	Desvio Padrão do Erro	Quantidade de vezes que o indivíduo foi eleito o melhor em 100 gerações
	Quantidade de camadas escondidas (a_{GA})	Quantidade de neurônios em cada camada escondida (b_{GA})			
1º	4	15	0,0058	0,0069	14
2º	1	10	0,0063	0,0056	13
3º	2	10	0,0082	0,0073	13
4º	1	8	0,0096	0,0058	12

A Figura 5.21 apresenta os quatro melhores indivíduos de cada geração, onde o eixo das abscissas é a quantidade de gerações e o eixo das ordenadas é a função de avaliação. Observa-se que devido a inicialização aleatória dos pesos da MLP no treinamento com o algoritmo de retropropagação do erro, as curvas de evolução do algoritmo genético para os quatro primeiros indivíduos de cada geração, apresentam oscilações no decorrer das gerações. Observa-se que a propriedade de elitismo não garante que a evolução do algoritmo genético ocorra de forma progressivamente decrescente a cada geração, para problemas cujo os indivíduos apresentem natureza estocástica. Desta forma, a melhor topologia foi escolhida identificando o indivíduo que mais foi eleito como o melhor em 100 gerações, como disposto na Tabela 5.10.

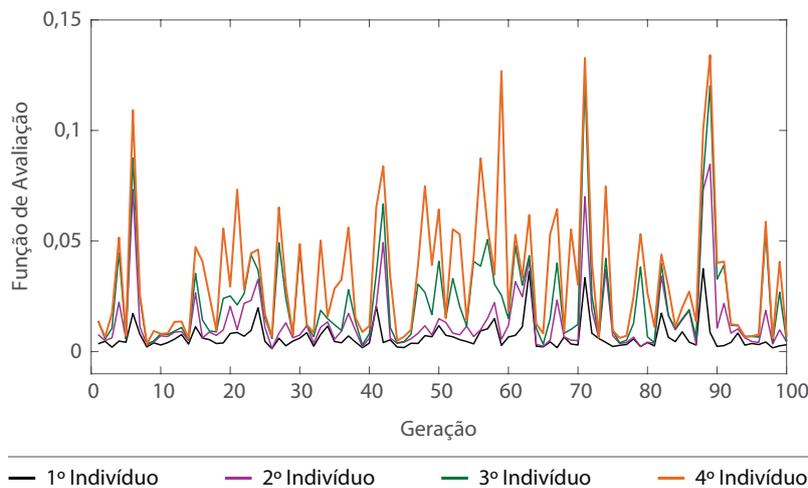


Figura 5.21 - Evolução do algoritmo genético para os quatro primeiros indivíduos de cada geração.

A Figura 5.22 apresenta o resultado da validação cruzada para a MLP com 32 neurônios na camada de entrada, quatro camadas escondidas com quinze neurônios cada e sete neurônios na camada de saída, onde 60% dos dados foram aplicados para treinamento, 20% para validação e 20% para teste. O eixo das ordenadas dado em escala logarítmica, apresenta o decaimento do erro quadrático médio entre a resposta desejada e a resposta da rede pela quantidade de épocas expresso no eixo das abscissas. A melhor performance da curva de validação foi encontrada na época 387, onde a partir deste ponto a MLP começa a ter excesso de treinamento (*overfitting*).

A Tabela 5.11 dispõe o percentual de reconhecimento da MLP ao submeter para testes as coletâneas utilizadas no treinamento com o algoritmo de retropropagação do erro. Diferentemente da etapa de validação que contou com 20% dos dados das

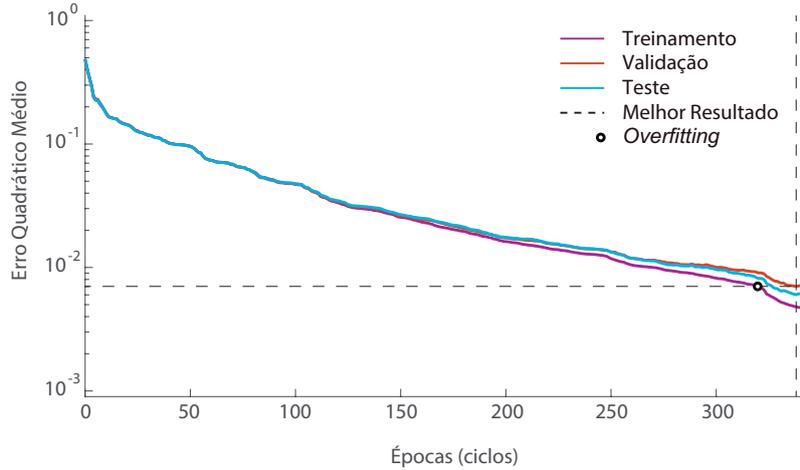


Figura 5.22 - Validação Cruzada do treinamento da MLP.

coletâneas para validar o reconhecimento de padrão, a etapa de teste, apresentado na Tabela 5.11, informa o percentual de reconhecimento da rede ao aplicar em sua entrada 100% dos dados das quatro coletâneas. Destaca-se que a rede ajustada identificou satisfatoriamente as coletâneas $\mathbf{M}_{F1(32 \times 1500 \times 7)}$, $\mathbf{M}_{F2(32 \times 1500 \times 7)}$, $\mathbf{M}_{F3(32 \times 1500 \times 7)}$ e $\mathbf{M}_{F4(32 \times 1500 \times 7)}$ submetidas para treinamento, como observado na Tabela 5.11, onde o menor acerto foi de 94,3% para a coletânea M_{F1} do Gleissolo Melânico Distrófico.

Tabela 5.11 - Treinamento da rede neural artificial.

Classificação dos Solos	Percentual de Reconhecimento da MLP				
	\mathbf{M}_{F1}	\mathbf{M}_{F2}	\mathbf{M}_{F3}	\mathbf{M}_{F4}	Média/Solo
Gleissolo Melânico Distrófico	94,3%	97,1%	96,2%	97,1%	96,1%
Latossolo Vermelho Ácrico	100%	100%	99,5%	100%	99,8%
Latossolo Vermelho Amarelo Distrófico Petroplântico	98,3%	100%	100%	100%	99,5%
Latossolo Vermelho Distrófico	100%	100%	100%	100%	100%
Luvissole Háplico	100%	100%	100%	100%	100%
Neossolo Flúvico Ta Distrófico	100%	100%	100%	100%	100%
Neossolo Quartzarênico Órtico	100%	100%	100%	100%	100%
Média/$\mathbf{M}_{F\sigma}$	98,9%	99,6%	99,4%	99,6%	99,3%

A coletânea $\mathbf{M}_{F5(32 \times 1500 \times 7)}$ não utilizada no treinamento foi apresentada a rede para reconhecimento dos padrões e os resultados estão dispostos na Tabela 5.12. A MLP apresentou reconhecimento insatisfatório para o Gleissolo Melânico Distrófico, indicando a necessidade de banco de dados com mais ensaios para alguns tipos de solos, garantindo a generalização.

Tabela 5.12 - Validação da rede neural artificial.

Classificação dos Solos	Percentual de Reconhecimento da MLP
	M_{F5}
Gleissolo Melânico Distrófico	53,2
Latossolo Vermelho Ácrico	97,8%
Latossolo Vermelho Amarelo Distrófico Petroplúntico	100%
Latossolo Vermelho Distrófico	100%
Luvissole Háptico	100%
Neossolo Flúvico Ta Distrófico	100%
Neossolo Quartzarênico Órtico	100%
Média de acerto da MLP	93%

5.4 Testes com solos não caracterizados

Para medir a eficiência do dispositivo e da metodologia proposta, realizou-se ensaios com solos não caracterizados. O intuito é aferir a eficiência da MLP em reconhecer o quão próximo o solo não caracterizado está em relação a solos já ensinados para a MLP. Para o ensaio de descaracterização adotou-se duas amostras, a primeira obtida do Neossolo Quartzarênico Órtico já ensinado para a MLP e a segunda obtida de solo não caracterizado, apresentado na Figura 5.23. Das duas amostras, realizou-se quatro ensaios para cada mistura de solo, onde: i) o primeiro ensaio foi realizado com 5g do solo não caracterizado, ii) o segundo ensaio com 3g do solo não caracterizado +2g do Neossolo Quartzarênico Órtico, iii) o terceiro ensaio com 2g do solo não caracterizado +3g do Neossolo Quartzarênico Órtico e iv) o quarto ensaio com 1g do solo não caracterizado +4g do Neossolo Quartzarênico Órtico.



Figura 5.23 - Solo não caracterizado.

As Figura 5.24(a) até Figura 5.24(f) apresentam as curvas de tensão produzidas nos fotodiodos $v = 1$, $v = 6$, $v = 12$, $v = 18$, $v = 24$, e $v = 30$, respectivamente, para os quatro ensaios realizados com as amostras misturadas de solos. Na Figura 5.24(a), observa-se que as tensões produzidas para o primeiro ensaio com 5g da amostra do solo não caracterizado, indicam alta turbidez nos primeiros primeiros 100 se-

gundos, sendo o tempo de alta turbidez prolongado nos últimos fotodiodos, como apresentado na Figura 5.24(f). A partir de aproximadamente 1000 segundos, na Figura 5.24(a), as curvas de tensão apresentam para todos os ensaios estabilização com baixa concentração de partículas.

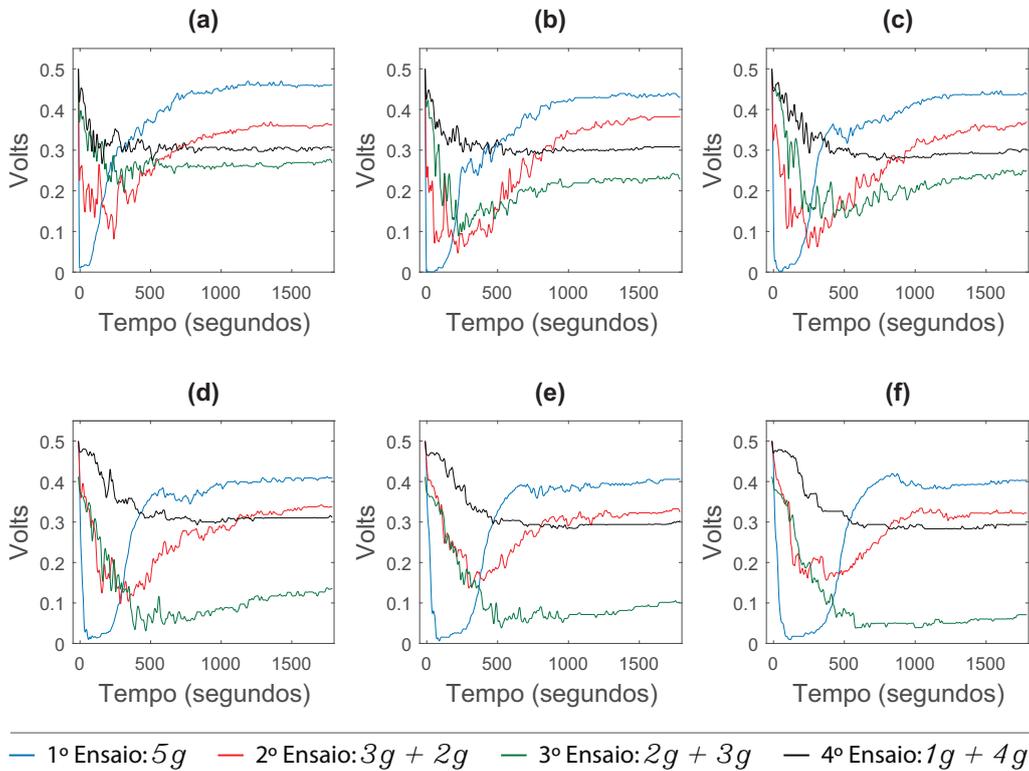


Figura 5.24 - Tensão produzida para quatro ensaios utilizando mistura de solo com amostras não caracterizadas no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Do segundo ensaio até o quarto, ao adicionar gradativamente $1g$ do Neossolo Quartzarênico Órtico, altera-se a dinâmica de turbidez e estabilização da sedimentação. Na Figura 5.25(a) até Figura 5.25(f) são apresentadas as curvas de tensão para o Neossolo Quartzarênico Órtico $k = 7$ e para o quarto ensaio com $1g$ do solo não caracterizado $+4g$ do Neossolo Quartzarênico Órtico, onde observa-se padrão semelhante entre as curvas de tensão \times tempo.

Na Figura 5.26(a) até Figura 5.26(f) são apresentadas as curvas de tensão para o Latossolo Vermelho Ácrico $k = 2$ e para o primeiro ensaio com $5g$ do solo não caracterizado, onde observa-se padrão semelhante entre as curvas de tensão \times tempo para este estudo de caso.

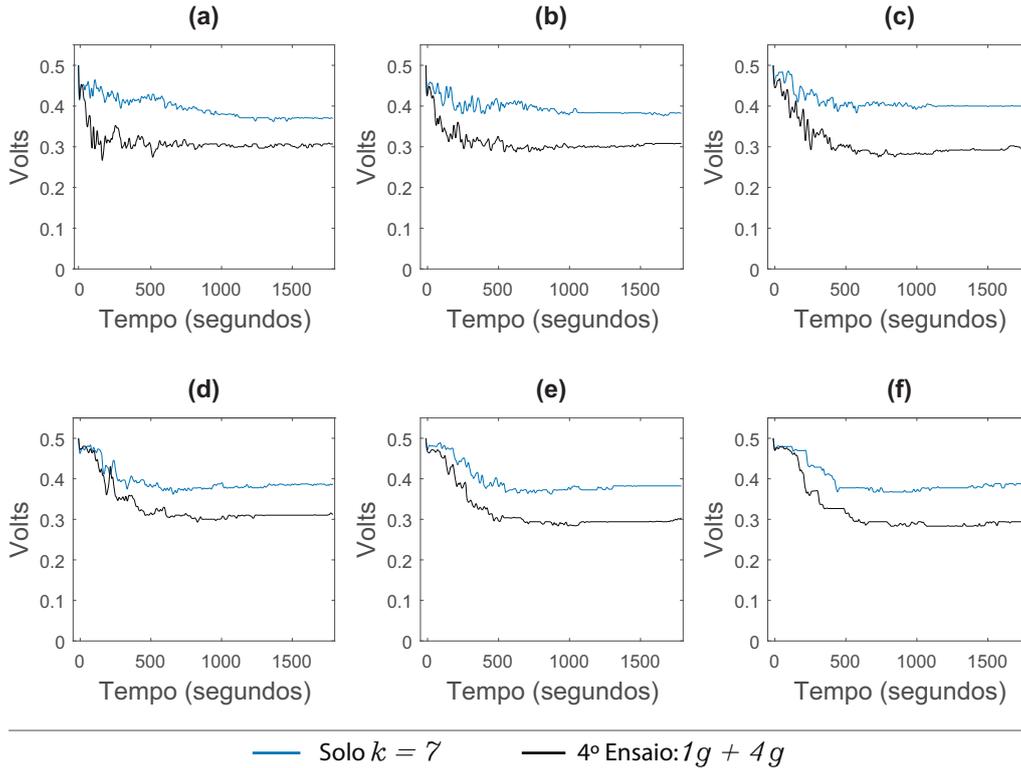


Figura 5.25 - Comparação da tensão produzida para o solo $k = 7$ e para o quarto ensaio com amostra de solo não caracterizado no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Para aferir a eficiência da MLP em reconhecer solos não caracterizados, utilizou-se a MLP treinada (ensinada) com as coletâneas M_{F1} , M_{F2} , M_{F3} e M_{F4} para reconhecer as curvas de tensão produzidas nos ensaios com as amostras não caracterizadas. A Tabela 5.13 dispõe o reconhecimento da rede para cada ensaio com amostras não caracterizadas, onde a semelhança de padrão, apresentada na Figura 5.26(a) até Figura 5.26(f), entre o solo não caracterizado e o Latossolo Vermelho Ácrico foi reconhecido pela MLP com 94,3% de semelhança. As curvas de tensão obtidas no quarto ensaio com a amostra descaracterizada, foi reconhecido pela MLP com 100% de semelhança como Neossolo Quartzarênico Órtico.

5.5 Análise de sensibilidade na projeção de variáveis

Para aferir se todos os fotodiodos produzem informação relevante para o modelo, aplicou-se o método de importância das variáveis de projeção (IVP) nos mínimos quadrados parciais para regressão (MQPR), adotando a coletânea $\mathbf{M}_{F1(32 \times 1500 \times 7)}^T$ como matriz de variáveis preditoras, e $\mathbf{S}_{(7 \times 1 \times 7)}$ como matriz de variáveis respos-tas. A Tabela 5.14 dispõe os resultados do IVP para cada fotodiodos do modelo,

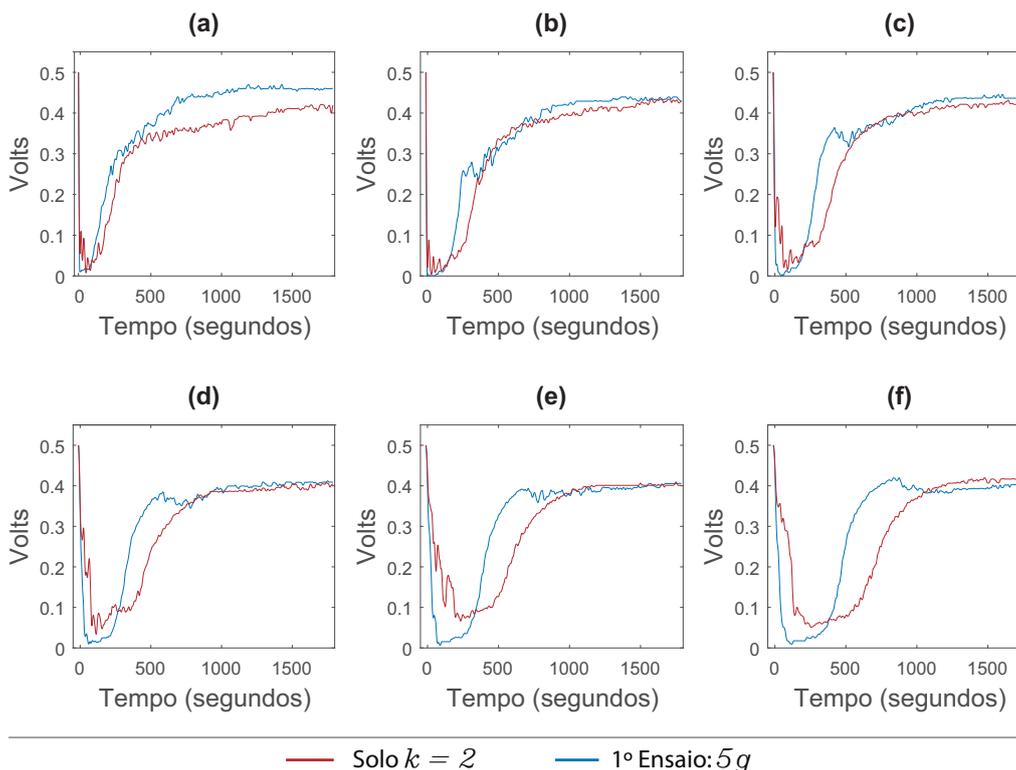


Figura 5.26 - Comparação da tensão produzida para o solo $k = 2$ e para o primeiro ensaio com amostra de solo não caracterizado no: (a) fotodiodo $v = 1$, (b) fotodiodo $v = 6$, (c) fotodiodo $v = 12$, (d) fotodiodo $v = 18$, (e) fotodiodo $v = 24$ e (f) fotodiodo $v = 30$.

Tabela 5.13 - Reconhecimento das amostras não caracterizadas.

Solos Classificados	Solos não Caracterizados			
	1º Ensaio	2º Ensaio	3º Ensaio	4º Ensaio
Gleissolo Melânico Distrófico	0,5%	24,8%	19,5%	31%
Latossolo Vermelho Ácrico	94,3%	100%	0%	33,8%
Latossolo Vermelho Amarelo Distrófico Petroplântico	0%	91%	100%	31,4%
Latossolo Vermelho Distrófico	0%	0%	0%	0%
Luvisolo Háptico	0%	0%	0%	0%
Neossolo Flúvico Ta Distrófico	0%	0%	0%	0%
Neossolo Quartzarênico Órtico	0%	0%	0%	100%

informando que dez fotodiodos apresentam $IVP > 1$, sendo os mais significativos na obtenção das informações do comportamento das partículas do solo em sedimentação.

5.6 Comentários

O dispositivo na configuração com dispersão de partículas, por ter a câmara de retenção fabricada em material poliacetal, contamina as amostras no momento da

Tabela 5.14 - Importância das variáveis de projeção para cada fotodiodo.

Fotodiodos	IVP	Fotodiodos	IVP
$v = 1$	1,592	$v = 17$	0,828
$v = 2$	1,197	$v = 18$	0,830
$v = 3$	1,115	$v = 19$	0,915
$v = 4$	1,032	$v = 20$	0,938
$v = 5$	0,803	$v = 21$	0,913
$v = 6$	1,032	$v = 22$	0,919
$v = 7$	1,028	$v = 23$	1,002
$v = 8$	0,854	$v = 24$	0,918
$v = 9$	0,906	$v = 25$	1,007
$v = 10$	1,664	$v = 26$	0,790
$v = 11$	0,919	$v = 27$	0,753
$v = 12$	0,766	$v = 28$	0,717
$v = 13$	0,831	$v = 29$	0,742
$v = 14$	0,902	$v = 30$	0,874
$v = 15$	0,945	$v = 31$	0,956
$v = 16$	0,843	$v = 32$	1,584

dispersão motorizada, por sofrer desgaste abrasivo das partículas em alta velocidade. Portanto, em estudos futuros a mesma deverá ser fabricada com material resistente e não contaminante. O módulo laser de baixa potência adotado apresentou-se insatisfatório para a configuração com dispersão de partículas. No entanto, foi adotado este módulo laser devido ao baixo custo e facilidade na aquisição.

O fotodiodo BPW34 apresentou-se satisfatório, tendo estabilidade na geração de tensão elétrica. O BPW34 da fabricante *Vishy*, é um $p - i - n$ fotodiodo (região semicondutora intrínseca ampla e não dopada entre o semicondutor do tipo p e n) especificamente desenvolvido para trabalhos de natureza de densitometria aplicada a foto sedimentação, como disposto na Tabela 5.15, retirada de Datasheet BPW34 (2008). No entanto, para utilizar o fotodiodo BPW34 com maior sensibilidade espectral relativa, é necessário adotar módulos lasers que operem na região infravermelho ($\lambda \approx 950nm$), atualmente de elevado custo e de difícil aquisição.

Tabela 5.15 - Aplicação dos fotodiodos da *Vishy*.

Aplicação	PIN Fotodiodo	Fotodiodo
Fotometria (medidor de luz)	-	BPW21R
Radiometria	TEMD5010X01, BPW34 e BPW24R	BPW20RF
Barreiras de luz	BPV10NF e BPW24R	-
Controle remoto, Filtro IR incluído ($\lambda > 900nm$)	BPV20F, BPV23F, BPW41N, S186P e TEMD5100X01	-
Transmissão de dados por infravermelho ($f_c < 10$ MHz), filtro IR incluído ($\lambda > 820nm$)	BPV23NF, BPW82, BPW83, BPV10NF, TEMD1020 e TEMD5110X01	-
Transmissão de dados IR ($f_c > 10MHz$), sem filtro IR	BPW34 , BPW46, BPV10 e TEMD5010X01	-
Densitometria	BPW34 , BPV10 e TEMD5010X01	BPW20RF e BPW21R
Detector de fumaça	BPV22NF, BPW34 e TEMD5010X01	

A Figura 5.27, Figura 5.28 e Figura 5.29 apresentam todas as curvas de tensão produzidas pelos fotodiodos $v = 1$, $v = 16$ e $v = 32$, respectivamente, para todos os solos da Tabela 5.2. Observa-se que os solos do tipo Latossolo $k = 2$, $k = 3$ e $k = 4$ apresentaram padrões diferente indicando diversidade na composição química e física de cada tipo de Latossolo. Os solos do tipo Neossolo $k = 6$ e $k = 7$ apresentaram padrão semelhante indicando solos mais homogêneos com baixa diversidade na composição das partículas, o que é esperado pois os solos do tipo Neossolo são jovens com partículas maiores e com geometrias distintas. As tensões produzidas pelos fotodiodos para os solos do tipo Gleissolo $k = 1$ e Luvissole $k = 5$ reforçam a eficácia do dispositivo em gerar curvas de tensão diferentes para cada tipo de solo.

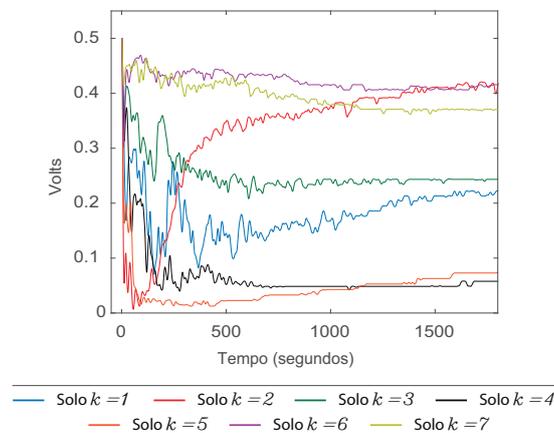


Figura 5.27 - Curvas de tensão produzidas pelo fotodiodo $v = 1$ para todos os solos da Tabela 5.2.

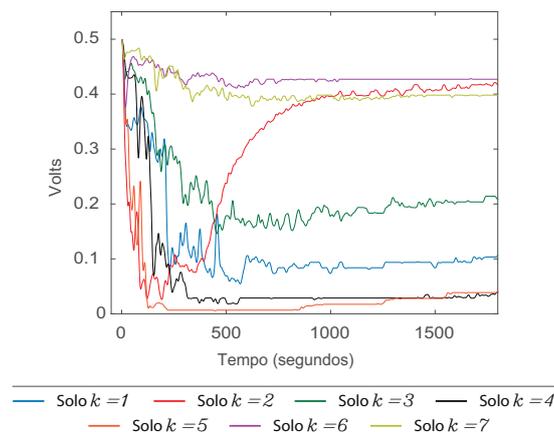


Figura 5.28 - Curvas de tensão produzidas pelo fotodiodo $v = 16$ para todos os solos da Tabela 5.2.

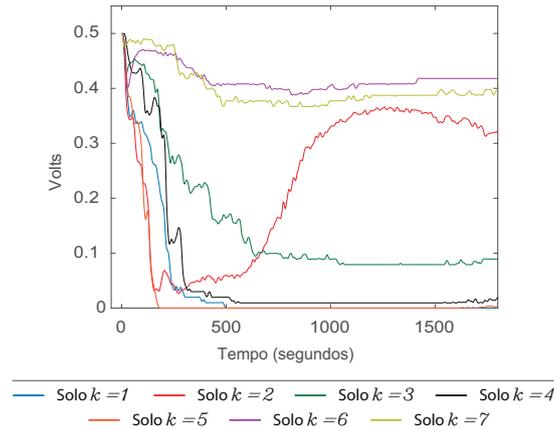


Figura 5.29 - Curvas de tensão produzidas pelo fotodiodo $v = 32$ para todos os solos da Tabela 5.2.

Observou-se que para os solos $k = 1$, $k = 2$, $k = 3$ e $k = 5$, 1500 segundos não foram suficientes para que a concentração de partículas se estabilize em determinados valores, apesar de ser tempo suficiente para identificar o comportamento do solo relacionado a sedimentação. Contudo, faz-se necessário banco de dados com maior quantidade de tipos de solo para estipular o tempo de leitura adequado, quantidade de ensaios por tipo de solo e quantidade de solo nas amostras.

A MLP treinada para os solos caracterizados no banco de dados apresentou a eficiência do método de reconhecimento em aproximadamente 99,3%. Contudo, observou-se a necessidade de aumentar a quantidade de ensaios para alguns tipos de solos, para garantir que solos com alta heterogeneidade no tamanho, formato geométrico e densidade das partículas, possam ser reconhecidos corretamente.

O método de importância das variáveis de projeção (IVP) nos mínimos quadrados parciais para regressão (MQPR) reconheceu dez fotodiodos como os mais relevantes na identificação do comportamento das partículas em sedimentação. No entanto, nenhum fotodiodo apresentou $IVP < 0,5$, tendo a maioria apresentado $IVP \approx 0,9$ indicando relevância de todos os fotodiodos. A Figura 5.30 ilustra o resultado apresentado na Tabela 5.14 de forma didática, onde os fotodiodos que obtiveram $IVP > 1$ estão em cores fortes. Conforme ilustrado, os fotodiodos $v = 1$, $v = 2$, $v = 3$ e $v = 4$ são os primeiros a receberem interferência luminosa das partículas liberadas da câmara de retenção para a câmara de sedimentação. As partículas recém liberadas estão sob influência de forças além da gravitacional, sendo observado que na maioria dos casos, a partir do fotodiodo $v = 10$ as partículas apresentam maior estabilidade. As curvas de tensão geradas pelos fotodiodos próximos aos fotodiodos

com $IVP > 1$, apresentam semelhanças com retardo temporal.

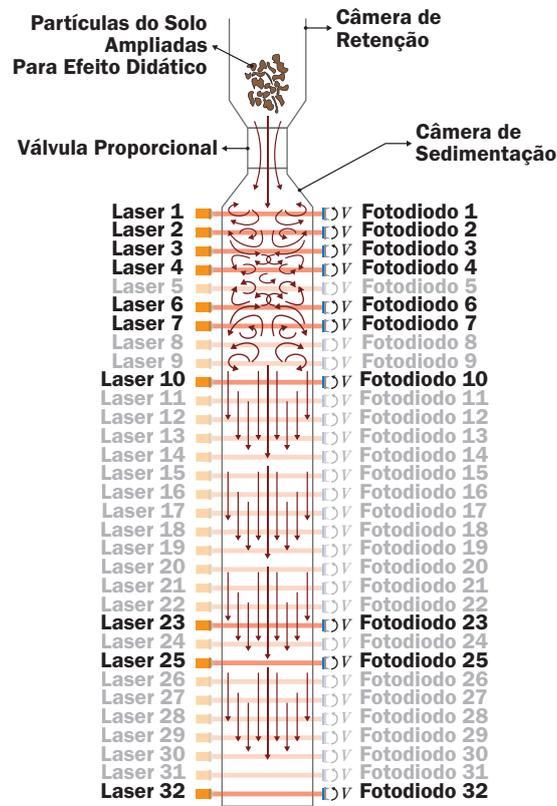


Figura 5.30 - Ilustração didática dos resultados da Tabela 5.14.

CAPÍTULO 6

CONCLUSÃO

Este trabalho desenvolveu dispositivo para caracterização do comportamento do solo em sedimentação e apresentou metodologia para reconhecimento do solo com informação significativa do comportamento da sedimentação. O dispositivo apresentou-se eficiente no mensuramento da taxa de sedimentação nos 32 pontos de foto medição, onde utilizando-se do princípio da foto sedimentação, cada ponto extraí informações relevantes na construção da matriz que representa o solo em análise.

O dispositivo conta com câmara de retenção e válvula proporcional para linearizar a forma com que as partículas são liberadas para o ensaio, possibilitando mensurar o instante em que as partículas começam a interceptar o feixe de luz monocromático. Este sistema permitiu a linearização da foto medição, auxiliando na identificação do comportamento das partículas em sedimentação, do instante inicial até a conclusão do ensaio. O período de foto medição estipulado neste trabalho foi de 1500 segundos para cada tipo de solo, no entanto observou-se que alguns tipos de solo apresentam estabilização no comportamento em sedimentação em tempo superior a 1500 segundos. Contudo, aferiu-se que 1500 segundos são suficientes para obter informações que diferenciem cada tipo de solo.

O solo é formado por partículas heterogêneas com tamanho, formato geométrico e densidades diferentes. Neste trabalho, realizou-se cinco ensaios com cada tipo de solo, onde utilizando a formula do erro quadrático médio verificou-se desvio de ordem inferior a 10^{-2} entre os ensaios. O desvio apresentado, indica a capacidade do dispositivo em mensurar a heterogeneidade das partículas de cada tipo de solo.

Comprovou-se que de posse das matrizes geradas pelo dispositivo, é possível construir o banco de dados e treinar o sistema de reconhecimento de padrões, para reconhecer os solos presentes no banco de dados de forma satisfatória. A rede neural artificial treinada é capaz de reconhecer os solos não caracterizados e indicar sua semelhança com solo cadastrado no banco de dados. Este trabalho configura-se como estudo inicial para o modelo proposto, maiores investigações em trabalhos futuros com mais solos classificados para análise deverão ser realizados.

6.1 Contribuições do Trabalho

Artigos em congresso:

MARTINS, D.; CALIXTO, W. P.; DAMIN, V. **Device for automatic particle size analysis and the of sedimentation using pattern recognition**. 18th IEEE International Conference on Environmental and Electrical Engineering. 2018.

6.2 Sugestões para Trabalhos Futuros

- Desenvolver dispositivo utilizando-se de foto emissores infravermelhos.
- Desenvolver dispositivo com proteção IP68.
- Construir banco de dados com mais de 100 amostras de solos classificados.
- Construir banco de dados utilizando tensores.
- Sistema de reconhecimento de padrões com aprendizado não-supervisionado.
- Aplicar o uso do dispositivo e das redes neurais para o desenvolvimento de funções de pedo transferência.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABNT. **NBR 7181: Análise Granulométrica**. Rio de Janeiro: [s.n.], 1984. 13 p. 44
- ABNT. **NBR 6457: Preparação para ensaios de compactação e ensaios de caracterização**. Rio de Janeiro: [s.n.], 1986. 9 p. 44
- ALLEN, T. **Particle Size Measurement**. 4. ed. New York: Chapman and Hall, 1990. 830 p. 28, 29
- ALMEIDA, B. G. de; DONAGEMMA, G. K.; RUIZ, H. A.; BRAIDA, J. A.; VIANA, J. H. M.; REICHERT, J. M. M.; OLIVEIRA, L. B.; CEDDIA, M. B.; WADT, P. S.; FERNANDES, R. B. A.; PASSOS, R. R.; DECHEN, S. C. F.; KLEIN, V. A.; TEIXEIRA, W. G. Padronização de métodos para análise granulométrica no Brasil. **Embrapa**, p. 1–11, 2012. 30
- ARBIB, M. A. **The Handbook of Brain Theory and Neural Networks**. 2. ed. London: The Mit Press, 2009. 1344 p. 50, 53
- BAEV, K. V. **Biological Neural Networks: Hierarchical Concept of Brain Function**. 1. ed. Boston: Birkhäuser Basel, 1996. 306 p. 49
- BERNARDI, A. C. d. C.; SILVA, C. A.; MACHADO, P. L. O. d. A. **Agricultura de precisão para o manejo da fertilidade do solo em sistema plantio direto**. Rio de Janeiro: Embrapa Solos, 2004. 29
- BERNHARDT, C. **Particle Size Analysis: Classification and sedimentation methods**. 1. ed. London: Springer Science, 1994. 437 p. 27, 28, 30, 46
- BIRKELAND, P. W. **Soils and Geomorphology**. 1. ed. New York: Oxford University Press, 1984. 391 p. 39
- BISHOP, C. M. **Pattern Recognition and Machine Learning**. 1. ed. New York: Springer, 2006. 749 p. 51
- BOUYOUCOS, G. J. The hydrometer as a new and rapid method for determining the colloidal content of soils. **Michigan Agric. Exp. Stn.**, v. 23, n. 4, p. 319–331, 1926. 28
- BRADY, N. C.; WEIL, R. R. **Elementos da natureza e propriedades dos solos**. 3. ed. São Paulo: [s.n.], 2013. 685 p. 27, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43

- BRASPENNING, P. J. **Artificial Neural Networks: An Introduction to ANN Theory and Practice**. 1. ed. Berlin: Springer, 1995. 295 p. 54
- BROWN, J. F.; SKREBOWSKI, J. K. A Comparison of Method for Particle Size Analysis. **Br. J. Appl. Sci.**, n. 3, p. 21–28, 1949. 28
- BUAH-BASSUAH, P. K.; EUZZOR, S.; FRANCINI, F.; QUANSAH, G. W.; SANSONI, P. Soil textural classification by a photosedimentation method. **Appl. Opt.**, v. 37, n. 3, p. 586–593, 1998. 30, 77
- CALIXTO, W. P. **Métodos matemático e computacional aplicados a prospecção geolétrica com estratificação tridimensional**. Tese (Doutorado) — Universidade Federal de Uberlândia, 2012. 57, 58
- CARON, P.; FAUCOMPRÉ, B.; MEMBREY, F.; FOISSY, A. A new white light photosedimentometer for solid - Liquid dispersion study: Device description, stability and settling behaviour. **Powder Technol.**, v. 89, n. 2, p. 91–100, 1996. 30, 77
- CARVALHO, N. d. O. **Hidrossedimentologia prática**. 1. ed. Rio de Janeiro: CPRM, 1994. 372 p. 30, 44
- CHAMBINO, M. T.; CORREIA, A.; COELHO, J. Floc characterisation by analysis of laser beam attenuation. **Environ. Technol.**, v. 25, n. 6, p. 657–665, 2004. 46
- CHESWORTH, W. **Encyclopedia of Soil Sciences**. 1. ed. New York: Springer Netherlands, 2008. 902 p. 27, 33, 36, 38, 40, 41
- COOLEN, A. C. C.; KUEHN, R.; SOLLICH, P. **Theory of Neural Information Processing Systems**. 1. ed. New York: Oxford University Press, 2005. 586 p. 52, 53, 54, 55, 56
- COPPIN, B. **Artificial Intelligence Illuminated**. 1. ed. Boston: Jones and Bartlett Publishers, 2004. 768 p. 50
- Datasheet BPW34. Measurement Techniques. **Vishay Semicond.**, p. 27–35, 2008. 101
- DEFELIPE, J. **Biological and Artificial Computation: From Neuroscience to Technology**. 1. ed. Berlin: Springer, 1997. 50

FAO. **Guidelines for Soil Description**. 4. ed. Roma: Food And Agriculture Organization of the United Nations, 2006. 109 p. [43](#)

FOTH, H. D. **Fundamentals of Soil Science**. 8. ed. New York: Wiley, 1990. 382 p. [38](#), [39](#), [41](#)

FRIEDMAN, M.; KANDEL, A. **Introduction To Pattern Recognition: Statistical, Structural, Neural and Fuzzy Logic Approaches**. 1. ed. Danvers: World Scientific Publishing Company, 1999. 345 p. [49](#)

GALINDO-PRIETO, B.; ERIKSSON, L.; TRYGG, J. Variable influence on projection (VIP) for orthogonal projections to latent structures (OPLS). n. April, 2014. [62](#)

GALIZIO, M. Contingency-shaped and rule-governed behavior: instructional control of human loss avoidance. **North**, n. I, p. 53–70, 1979. [49](#)

GALUSHKIN, A. I. **Neural Networks Theory**. 1. ed. Berlin: Springer, 2007. 402 p. [53](#)

GEN, M.; CHENG, R.; LIN, L. **Network models and optimization: multiobjective genetic algorithm approach**. London: Springer, 2008. 701 p. [57](#)

HADDAD, J. E.; ISMAEL, A.; GALLOU, G.; MICHEL, K.; BRUYERE, D.; LAPERCHE, V.; CANIONI, L.; BOUSQUET, B.; HADDAD, J. E.; ISMAEL, A.; GALLOU, G.; MICHEL, K. Artificial neural network for on-site quantitative analysis of soils using laser induced breakdown spectroscopy. **Spectrochim. Acta Part B At. Spectrosc.**, v. 79-80, 2012. [29](#)

HAGAN, M. T.; BEALE, M. H. **Neural Network Design**. 2. ed. New York: Thomson Learning (PWS), 2014. 1012 p. [55](#), [56](#)

HANRAHAN, G. **Artificial Neural Networks in Biological and Environmental Analysis**. 1. ed. Danvers: CRC Press, 2011. 210 p. [50](#), [52](#)

HASENFUSS, A.; HAMMER, B.; ROSSI, F. **Artificial Neural Networks in Pattern Recognition**. 1. ed. Paris: Springer, 2008. 326 p. [53](#)

HAYKIN, S. **Redes Neurais Princípios e Prática**. 2. ed. São Paulo: Bookman, 2001. 900 p. [49](#), [52](#), [53](#), [54](#), [55](#), [56](#)

HE, X.; XU, S. **Process Neural Networks: Theory and Applications**. 1. ed. Hangzhou: Springer, 2010. 253 p. 53

HILLEL, D. **Environmental soil physics**. 1. ed. San Diego: Academic Press, 2003. 801 p. 41, 42

HU, Y. H.; HWANG, J.-N. **Handbook of Neural Network Signal Processing**. 1. ed. Boca Raton: CRC Press, 2002. 384 p. 53

HULST, H. C. van de. **Light Scattering by Small Particles**. New York: John Wiley & Sons, 1957. 470 p. 28

IBGE. **Manual técnico de pedologia**. 2. ed. Rio de Janeiro: IBGE, 2007. 316 p. 33, 39, 42, 43

JOHNSTON, J. E.; ROSEN, L. J. Particle characterization using the photoscan. **Powder Technol.**, v. 14, n. 2, p. 195–201, 1976. 29

KO, Y. D.; SHANG, H. A neural network-based soft sensor for particle size distribution using image analysis. **Powder Technol.**, Elsevier B.V., v. 212, n. 2, p. 359–366, 2011. 29

KRAMER, O. **Genetic Algorithm Essentials 123**. Gewerbestrasse: Springer, 2017. 57

KRISHNAN, A.; WILLIAMS, L. J.; RANDAL, A.; ABDI, H. NeuroImage Partial Least Squares (PLS) methods for neuroimaging : A tutorial and review. **Neuroimage**, Elsevier Inc., 2010. ISSN 1053-8119. 60

KUBITSCHKEK, H. E. Electronic counting and sizing of bacteria. **Nature**, v. 182, n. 4630, p. 234–235, 1958. 28

LAKE, H. R.; AKBARZADEH, A.; MEHRJARDI, R. T. Development of pedo transfer functions (PTFs) to predict soil physico-chemical and hydrological characteristics in southern coastal zones of the Caspian Sea. **Ecol. Nat. Environme**, v. 1, n. 7, p. 160–172, 2009. 30

LAL, R.; SHUKLA, M. K. **Principles of Soil Physics**. 1. ed. New York: MARCEL DEKKER, 2004. 699 p. 27, 35, 45

LEONDES, C. T. **Image Processing and Pattern Recognition - Neural Network Systems Techniques and Applications**. 1. ed. San Diego: Academic Press, 1998. 407 p. 49

LEPSCH, I. F. **Formação e Conservação dos Solos**. 2. ed. São Paulo: Oficina de Textos, 2002. 178 p. [33](#), [34](#), [37](#), [38](#), [44](#)

MERKUS, H. G. **Particle Size Measurements: Fundamentals, Practice, Quality**. 1. ed. Pijnacker: Springer Netherlands, 2009. 534 p. [27](#), [28](#), [46](#)

NASCIMENTO, C.; GUARDANI, R.; GIULIETTI, M. Use of neural networks in the analysis of particle size distribution by laser diffraction: tests with different particle systems. **Powder Technol.**, v. 126, n. 1, p. 42–50, 2002. [29](#)

NAVARICK, D. The experimental analysis of human behavior. **J. Exp. Anal. Behav.**, v. 54, n. 3, p. 159–162, 1990. [49](#)

O'BRIEN, R. W. Electro-acoustic effects in a dilute suspension of spherical particles. **J. Fluid Mech.**, v. 190, p. 71–86, 1988. [29](#)

PACHECO, L. Atividade de herbicidas pré-emergentes em solos do cerrado, na presença e ausência de resíduos orgânicos. **Programa Pós-Graduação em Agron.**, p. 1–102, 2017. [81](#)

PASSINO, K. M. **Biomimicry for optimization, control, and automation**. 1. ed. London: Springer, 2005. 933 p. [57](#)

PERELMAN, Y.; GINOSAR, R. **The NeuroProcessor: An Integrated Interface to Biological Neural Networks**. 1. ed. Haifa: Springer, 2009. 126 p. [50](#)

PURI, M.; PATHAK, Y.; SUTARIYA, V. K.; TIPPARAJU, S.; MORENO, W. **Artificial Neural Network for Drug Design, Delivery and Disposition**. 1. ed. New York: Elsevier Academic Press, 2016. 440 p. [52](#), [55](#), [56](#)

RICHARDSON, J. L.; VEPRASKAS, M. J. **Wetland Soils - Genesis, Hydrology, Landscapes, and Classification**. 1. ed. New York: Lewis Publishers, 2001. 432 p. [36](#)

ROBINSON, G. W. A new method for the mechanical analysis of soils and other dispersions. **J. Agric. Sci.**, v. 12, p. 306–321, 1922. [28](#)

SANTOS, H. G. dos; ALMEIDA, J. A.; OLIVEIRA, J. B. de; LUMBRERAS, J. F.; ANJOS, L. H. C. dos; COELHO, M. R.; JACOMINE, P. K. T.; CUNHA, T. J. F.; OLIVEIRA, V. Á. de. **Sistema brasileiro de classificação de solos**. 2. ed. Rio de Janeiro: EMBRAPA-SPI, 2006. 306 p. [36](#), [37](#), [70](#)

- SANTOS, R. D. dos; LEMOS, R. C. de; SANTOS, H. G. dos; KER, J. C.; ANJOS, L. H. cunha dos. **Manual de Descrição e Coleta de Solo no Campo**. 5. ed. Viçosa: Editora Folha de Viçosa Ltda., 2005. 92 p. 42
- SCHAETZL, R. J.; ANDERSON, S. **Soils: Genesis and Geomorphology**. 1. ed. New York: Cambridge University Press, 2005. 832 p. 39, 43
- SILVA, B. C. R. **Desenvolvimento de tecnologia baseada em redes neurais artificiais para reconhecimento de gestos em língua de sinais**. Dissertação (Mestrado): Universidade Federal de Goiás, 2018. 52, 55
- SILVA, I. N. da; FLAUZINO, D. H. S. R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. 1. ed. São Paulo: Artliber Editora, 2010. 399 p. 50, 51, 52
- SILVA, L. F. A. **Índices e indicadores socioeconômicos, científicos e tecnológicos como parâmetros para modelo de previsão**. Dissertação (Mestrado): Instituto Federal de Educação, Ciência e Tecnologia de Goiás, 2018. 52
- SKINNER, B. F. **Contingencies of Reinforcement: A Theoretical Analysis**. [S.l.: s.n.], 1969. 1–311 p. 50
- SMITH, K. a.; MULLINS, C. E. **Soil and Environmental Analysis**. 2. ed. New York: CRC Press, 2000. 637 p. 39
- SYVITSKI, J. P. M. **Principles, Methods and Application of Particle Size Analysis**. 1. ed. New York: Cambridge University Press, 2007. 388 p. 27, 29
- TENENHAUS, M. **La régression PLS: théorie et pratique**. Paris: Editions Technip, 1998. 62
- THENG, B. **Formation and Properties of Clay-Polymer**. 1. ed. Amsterdam: Academic Press, 2012. 503 p. 41, 42
- THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern Recognition**. 4. ed. San Diego: Academic Press, 2008. 957 p. 49, 50
- USDA. **Keys to Soil Taxonomy**. 13. ed. [S.l.]: United States Department of Agriculture, 2014. 372 p. 27, 33, 36, 37
- USDA. **Soil Survey Manual**. [S.l.]: United States Department of Agriculture, 2017. 639 p. 38, 42

VAZ, C.; OLIVEIRA, J.; REICHARDT, K.; CRESTANA, S.; CRUVINEL, P.; BACCHI, O. Soil mechanical analysis through gamma ray attenuation. **Soil Technol. Cremlingen**, v. 5, p. 1992, 1992. 28

VERRUIJT, A. **Soil Mechanics**. 1. ed. Amsterdam: VSSD, 2008. 315 p. 44, 45

WASHINGTON, C. **Particle Size Analysis In Pharmaceuticals And Other Industries: Theory And Practice**. 1. ed. West Sussex: Taylor & Francis, 1992. 260 p. 45, 46

WOLD, S.; SJOSTROM, M.; ERIKSSON, L. PLS-regression : a basic tool of chemometrics. p. 109–130, 2001. 60

