



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA HIDRÁULICA E AMBIENTAL**  
**PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL**

**ABRAHAM AUGUSTO BARBOSA GADELHA**

**ESTIMATIVA DE PARÂMETROS GEOTÉCNICOS DE RESÍDUOS**  
**SÓLIDOS URBANOS UTILIZANDO ALGORITMOS DE APRENDIZADO**  
**DE MÁQUINA**

**FORTALEZA**

**2021**

ABRAHAM AUGUSTO BARBOSA GADELHA

ESTIMATIVA DE PARÂMETROS GEOTÉCNICOS DE RESÍDUOS SÓLIDOS  
URBANOS UTILIZANDO ALGORITMOS DE APRENDIZADO DE MÁQUINA

Dissertação apresentada à Coordenação do Curso de Pós-Graduação em Engenharia Civil do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do título de mestre em Engenharia Civil. Área de Concentração: Geotecnia

Orientador: Prof. Dr. Anderson Borghetti Soares

Coorientador: Prof. Dr. Guilherme de Alencar Barreto

FORTALEZA

2021

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Biblioteca Universitária  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

B1e BARBOSA GADELHA, ABRAHAM AUGUSTO.  
ESTIMATIVA DE PARÂMETROS GEOTÉCNICOS DE RESÍDUOS SÓLIDOS URBANOS  
UTILIZANDO ALGORITMOS DE APRENDIZADO DE MÁQUINA / ABRAHAM AUGUSTO  
BARBOSA GADELHA. – 2021.  
184 f. : il. color.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Civil: Geotecnia, Fortaleza, 2021.

Orientação: Prof. Dr. Anderson Borghetti Soares.

Coorientação: Prof. Dr. Guilherme de Alencar Barreto .

1. Resíduos Sólidos Urbanos . 2. Redes Neurais. 3. Multilayer Perceptron. 4. Extreme Learning Machine.  
5. Least-Square Support Vector Regression. I. Título.

---

CDD 624.15

ABRAHAM AUGUSTO BARBOSA GADELHA

ESTIMATIVA DE PARÂMETROS GEOTÉCNICOS DE RESÍDUOS SÓLIDOS  
URBANOS UTILIZANDO ALGORITMOS DE APRENDIZADO DE MÁQUINA

Dissertação apresentada à Coordenação do  
Curso de Pós-Graduação em Engenharia Ci-  
vil do Centro de Tecnologia da Universidade  
Federal do Ceará, como requisito parcial à  
obtenção do título de mestre em Engenharia  
Civil. Área de Concentração: Geotecnia

Aprovada em:

BANCA EXAMINADORA

---

Prof. Dr. Anderson Borghetti Soares  
(Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Guilherme de Alencar Barreto  
(Coorientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Silvrano Adonias Dantas Neto  
(Examinador Interno)  
Universidade Federal do Ceará (UFC)

---

Prof. Dra. Márcia Maria dos Anjos Mascarenha  
(Examinadora Externa)  
Universidade Federal de Goiás (UFG)

Dedico este trabalho ao melhor professor que tive até agora, Raimundo Nonato Gadelha (*in memoriam*) e à sua carinhosa e zelosa parceira, Rosa Maria Barbosa Gadelha. Ao amor, esforço e sacrifício que foram despendidos e fazem parte da minha trajetória.

## AGRADECIMENTOS

Agradeço a Deus, Jesus Cristo, pela minha saúde e pelo dom da minha vida. Agradeço por iluminar o meu caminho e me presentear através das pessoas e situações que contribuíram com a conclusão deste trabalho.

A minha mãe, Rosa Maria Barbosa Gadelha, pelo amor e zelo incondicional. A minhas irmãs Pricisila e Dina pelo respeito e confiança. A minha madrinha, Kita, minha avó, Marlene, e todos meus familiares pelo amor e respeito.

A minha namorada Sayonara Bessa Cidrack pela compreensão da minha ausência, pelo apoio e pela confiança depositada em mim. Agradeço pelo incentivo e pelo alívio que me traz com seu amor.

Ao Professor Anderson Borghetti Soares pela confiança, compreensão e paciência durante todo o processo de desenvolvimento da minha pesquisa. Ao Professor Guilherme de Alencar Barreto pela admirável dedicação e pelo incentivo a criatividade.

Aos Professoras Alfran e Chagas pela dedicação ao ensino e pelo aprendizado adquirido durante as cadeiras do mestrado em Geotecnia. Aos Professores Márcia Maria e Silvrano pela aceitação da participação na minha banca.

Aos meus grandes amigos de faculdade Jonatas e Davi Sampaio por dividir momentos de crescimento profissional, alegrias e dificuldades da vida acadêmica. Agradeço a todos momentos que nossa amizade foi posta a prova e demonstrou o seu valor através da lealdade, tolerância e respeito.

Aos meus amigos de colégio Bruno, Alan, Daniel, Caio, João, Alexandre e Puskas pela companhia e momentos de alegria que serviram de estímulo e alívio para mim. Ao meu amigo de infância Cleiton pelo carinho e todo o companheirismo que se mantém vivos mesmo nos momentos mais difíceis até hoje. Ao meu amigo Davi Bacelar pelo respeito, pela confiança, pelo compartilhar de ideias e diferentes perspectivas comigo que me fazem crescer.

Ao Doutorando em Engenharia Elétrica, Ednardo Moreira Rodrigues, e seu assistente, Alan Batista de Oliveira, aluno de graduação em Engenharia Elétrica, pela adequação do *template* utilizado neste trabalho para que o mesmo ficasse de acordo com as normas da biblioteca da Universidade Federal do Ceará (UFC).

“Ser feliz ao realizar a jornada pode ser muito  
melhor do que chegar ao destino com sucesso.”

(Jordan Bernt Peterson)

## RESUMO

A progressiva expansão de aterros sanitários reforça a necessidade de desenvolvimento de projetos em engenharia geotécnica que representem seu comportamento mecânico durante sua construção e manutenção. A realização de um programa completo de ensaios para determinação da envoltória de Mohr-Coulomb, segundo o critério de deformação, exige bastantes recursos e tempo. A utilização de modelagem e estimativas é uma alternativa explorada, sendo pouco utilizado o aprendizado de máquina. Nos trabalhos de [Falamaki e Shahin \(2018\)](#) as redes neurais *Radial Basis Function* (RBF) e *Multilayer-Perceptron* (MLP) apresentaram bons resultados de aproximação a partir das propriedades físicas dos Resíduos Sólidos Urbanos (RSU), sendo obtidos coeficiente de correlação linear de 0,97 e 0,89, respectivamente, para o intercepto coesivo e ângulo de atrito efetivos. No presente trabalho foi realizada uma aproximação empregando métodos de aprendizado de máquina, sendo necessária uma coleta de dados de 61 ensaios triaxiais da literatura resultando em 197 observações de intercepto coesivo e ângulo de atrito efetivos. Os dados de entrada coletados foram a composição gravimétrica; tempo de decomposição; teor de umidade; peso específico seco; deformação axial específica e tensão de confinamento máxima. Os algoritmos utilizados foram as redes neurais *Extreme Learning Machine* (ELM); MLP e o *Least-Squares Support Vector Regression* (LS-SVR), sendo executados através do programa *GNU Octave*. O melhor resultado de aproximação foi obtido para o algoritmo LS-SVR, sendo alcançado um coeficiente de determinação de 0,98 para o intercepto coesivo efetivo e 0,97 para o ângulo de atrito efetivo. Dentre as redes neurais a MLP obteve um desempenho superior a ELM. No final foi examinada uma representação do aterro sanitário de Santo Tirso a partir dos dados de [Gomes \(2008\)](#), sendo executada uma estimativa da envoltória de Mohr-Coulomb com as redes neurais e uma análise de estabilidade de talude do perfil do aterro no *Slide*. Nas análises as diferenças obtidas representaram uma discrepância máxima de 1,8 % dentre os fatores de segurança calculados e o admitido.

**Palavras-chave:** Aprendizado de máquina. Resíduos Sólidos Urbanos. Propriedades físicas. Deformação axial específica. Intercepto coesivo efetivo. Ângulo de atrito efetivo.



## ABSTRACT

The progressive expansion of sanitary landfills urges for the demand of project development in geotechnical engineering to characterize mechanical behavior during construction and maintenance. The execution of a complete test program to determine the Mohr-Coulomb envelope, under the axial strain criteria, requires great amounts of resources and time. The use of modelling and approximation is another used possibility, even though machine learning is not widely used. In the research of [Falamaki e Shahin \(2018\)](#) the Radial Basis Function (RBF) and Multilayer Perceptron (MLP) neural networks produced good approximation results originated from physical properties of Municipal Solid Waste (MSW) which corresponded in a linear correlation coefficient of 0.97 and 0.89, respectively, for effective cohesive intercept and effective friction angle. In the present study, an approximation was conducted employing machine learning methods, demanding that data of 61 triaxial tests from the literature were collected which result to 197 observations of effective cohesive intercept and effective friction angle. The input data collected were gravimetric composition; decomposition time; water content; dry unit weight; axial strain and maximum confining pressure. The executed algorithms were the neural network Extreme Learning Machine (ELM), MLP and Least-Squares Support Vector Regression (LS-SVR) that has been applied using the software GNU Octave. The best estimate was obtained for the LS-SVR that result in a coefficient of determination of 0.98 for effective cohesive intercept and a 0.97 for effective friction angle. The MLP performed better than ELM in general. The final part of the study was modeling a depiction of Santo Tirso's landfill from the data included in [Gomes \(2008\)](#) being executed a approximation of Mohr-Coulomb envelope with the neural network and a slope stability analysis for Santo Tirsos's landfill in the Slide. In the analysis the maximum difference obtained was represented by a variance of 1.8% between the safety factors calculated and the employed one.

**Keywords:** Machine Learning. Municipal Solid Waste. Physical properties. Axial strain. Effective cohesive intercept. Effective friction angle

## LISTA DE FIGURAS

Figura 2.1 – Composição gravimétrica de aterros sanitários . . . . .	24
Figura 2.2 – Classificação de Resíduos Sólidos Urbanos (RSU) pelo diagrama triangular	27
Figura 2.3 – Matéria orgânica × umidade de antigos aterros no Canadá . . . . .	28
Figura 2.4 – Efeitos da coesão com o teor de umidade RSU . . . . .	29
Figura 2.5 – Relação entre teor de matéria orgânica oxidável e a idade dos resíduos .	31
Figura 2.6 – Efeito do ângulo de atrito com o tempo . . . . .	32
Figura 2.7 – Modelo esquemático da composição dos RSU . . . . .	32
Figura 2.8 – Mobilização da coesão e ângulo de atrito com os níveis de deformação	33
Figura 2.9 – Resistência ao cisalhamento pela direção das fibras . . . . .	35
Figura 2.10–Envoltória de Mohr-Coulomb de diferentes tipos de resíduos . . . . .	36
Figura 2.11–Comparativo tensão desvio e deformação axial: areia, areia e fibras e RSU . . . . .	36
Figura 2.12–Comparação entre parâmetros de resistência do RSU . . . . .	37
Figura 2.13–Neurônio biológico . . . . .	41
Figura 2.14–Neurônio artificial . . . . .	42
Figura 2.15–Representação de uma rede neural <i>feedforward</i> com uma camada oculta	43
Figura 2.16–Representação do sentido das fases <i>forward</i> e <i>backward</i> . . . . .	45
Figura 2.17–Busca em gradiente na superfície do erro . . . . .	47
Figura 2.18–Vetores de Suporte em Classificação . . . . .	51
Figura 2.19–Truque de Kernel . . . . .	54
Figura 3.1 – Etapas do procedimento adotado . . . . .	56
Figura 3.2 – Representação das saídas coletadas: $c'$ (kPa) x $\phi'$ (°) . . . . .	63
Figura 4.1 – Coeficiente de Determinação ( $R^2$ ) pelo número de neurônios na camada oculta . . . . .	71
Figura 4.2 – <i>Mean Square Error</i> (MSE) pelo número de neurônios na camada oculta	72
Figura 4.3 – $c'$ - <i>Mean Square Error</i> pelo número de <i>epochs</i> . . . . .	73
Figura 4.4 – $\phi'$ - <i>Mean Square Error</i> pelo número de <i>epochs</i> . . . . .	73
Figura 4.5 – MLP - GOMES (2008) AM2- - $c'$ (kPa) x $\varepsilon_a$ (%): Real x Predito . . .	74
Figura 4.6 – MLP - CARVALHO (1999) - T2B12sat - $c'$ (kPa) x $\varepsilon_a$ (%): Real x Predito	75
Figura 4.7 – MLP - GRISOLIA (1995) - $c'$ (kPa) x $\varepsilon_a$ (%): Real x Predito . . . . .	75

Figura 4.8 – <i>Multi-Layer Perceptron</i> (MLP) - GOMES (2008) - AM3 – B1I <sub>2</sub> - c'(kPa) x $\varepsilon_a$ (%): Real x Predito . . . . .	76
Figura 4.9 – MLP - NASCIMENTO (2007) - 4anosCD10sat - c'(kPa) x $\varepsilon_a$ (%): Real x Predito . . . . .	77
Figura 4.10–MLP - GOMES (2008) AM2 – A4I <sub>2</sub> - $\phi'$ ( $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito .	78
Figura 4.11–MLP - CARVALHO (1999) - T1B12nat - $\phi'$ ( $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito	78
Figura 4.12–MLP - GRISOLIA (1995) - $\phi'$ ( $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito . . . . .	79
Figura 4.13–MLP - CARVALHO (1999) - T2B12nat - $\phi'$ ( $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito	80
Figura 4.14–Coeficiente de Determinação ( $R^2$ ) pelo número de neurônios . . . . .	81
Figura 4.15– <i>Mean Square Error</i> (MSE) pelo número de neurônios . . . . .	82
Figura 4.16– <i>Extreme Learning Machine</i> (ELM) - GOMES (2008) AM2 – A4I <sub>2</sub> : c'(kPa) x $\varepsilon_a$ (%): Real x Predito . . . . .	83
Figura 4.17–ELM GOMES (2008) - AM3- - c'(kPa) x $\varepsilon_a$ (%): Real x Predito . . .	83
Figura 4.18–ELM - NASCIMENTO (2007) - 4anosCD10sat - c'(kPa) x $\varepsilon_a$ (%): Real x Predito . . . . .	84
Figura 4.19–ELM - GOMES (2008) - AM2 – A4I <sub>2</sub> - $\phi'$ ( $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito	85
Figura 4.20–ELM - CARVALHO (1999) - T1B12nat - $\phi'$ ( $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito	85
Figura 4.21–ELM - GRISOLIA (1995) - $\phi'$ ( $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito . . . . .	86
Figura 4.22– <i>Least Squares-Suport Vector Regression</i> (LS-SVR) GOMES (2008) - AM2 – A4I <sub>2</sub> : c'(kPa) x $\varepsilon_a$ (%): Real x Predito . . . . .	88
Figura 4.23–LS-SVR GOMES (2008) - AM3 – B1I <sub>2</sub> : c'(kPa) x $\varepsilon_a$ (%): Real x Predito	89
Figura 4.24–LS-SVR - NASCIMENTO (2007) - 4anosCD10sat - c'(kPa) x $\varepsilon_a$ (%): Real x Predito . . . . .	89
Figura 4.25–LS-SVR GOMES (2008) - AM2 – A4I <sub>2</sub> : $\phi$ , ' $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito	90
Figura 4.26–LS-SVR CARVALHO (1999) - T1B12nat: $\phi$ , ' $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito . . . . .	91
Figura 4.27–LS-SVR GRISOLIA (1995): $\phi$ , ' $^\circ$ ) x $\varepsilon_a$ (%): Real x Predito . . . . .	91
Figura 4.28–Aterro de Santo Tirso na fase final de exploração . . . . .	93
Figura 4.29–Perfil transversal da área estudada por GOMES (2008) . . . . .	94
Figura 4.30–Perfil transversal da representação do aterro de Santo Tirso . . . . .	98
Figura 4.31–Representação do perfil no Slide para as redes neurais ELM e MLP . .	101
Figura 4.32–Fator de segurança do perfil do aterro: dados coletados . . . . .	102

Figura 4.33–Fator de segurança do perfil do aterro: rede neural MLP . . . . .	103
Figura 4.34–Fator de segurança do perfil do aterro: rede neural ELM . . . . .	103
Figura D.1–Planta horizontal das estações e resíduos estudados . . . . .	124
Figura E.1 –Perfil longitudinal das estações e resíduos estudados . . . . .	125

## LISTA DE TABELAS

Tabela 2.1 – Panorama dos sistemas de classificação existentes . . . . .	25
Tabela 2.2 – Sistema de Classificação por GRISOLIA <i>et al</i> (1995) . . . . .	26
Tabela 2.3 – Peso específico do RSU . . . . .	30
Tabela 2.4 – Principais funções <i>Kernel</i> . . . . .	55
Tabela 3.1 – Resumo da coleta de ensaios triaxiais por autor . . . . .	58
Tabela 3.2 – Estatística descritiva dos dados de entrada dos RSU . . . . .	64
Tabela 3.3 – Variância dos componentes principais: nominal, explicada e explicada acumulada . . . . .	66
Tabela 4.1 – <i>Grid-search</i> rede neural MLP: N <sup>o</sup> de neurônios, N <sup>o</sup> de parâmetros, MSE e R <sup>2</sup> das amostras de treino e validação . . . . .	71
Tabela 4.2 – <i>Grid-search</i> rede neural ELM:N <sup>o</sup> de neurônios, N <sup>o</sup> de parâmetros, MSE e R <sup>2</sup> das amostras de treino e validação . . . . .	81
Tabela 4.3 – <i>Global-random-search</i> LS-SVR:Parâmetros, limite inferior, superior, solução, MSE e R <sup>2</sup> das amostras de treino e validação . . . . .	87
Tabela 4.4 – Resumo das amostras coletadas de RSU . . . . .	96
Tabela 4.5 – Dados geotécnicos e representação do perfil do aterro . . . . .	98
Tabela 4.6 – Dados geotécnicos estimados e representação do perfil do aterro para a rede neural MLP . . . . .	99
Tabela 4.7 – Dados geotécnicos estimados e representação do perfil do aterro para a rede neural ELM . . . . .	100
Tabela A.1 – Dados de entrada coletados . . . . .	126
Tabela B.1 – Dados de saídas coletadas . . . . .	141
Tabela C.1 – MLP: resultados observados e preditos da amostra total dos dados . . . . .	149
Tabela D.1 – ELM: resultados observados e preditos da amostra total dos dados . . . . .	157
Tabela E.1 – LSSVR: resultados observados e preditos para amostra total dos dados . . . . .	165
Tabela F.1 – MLP: Resultados do aterro de Santo Tirso . . . . .	173
Tabela G.1 – ELM: Resultados do aterro de Santo Tirso . . . . .	179

## LISTA DE ABREVIATURAS E SIGLAS

AMAVE	Associação de Municípios do Vale do Ave
CD	<i>Consolidated Drained</i>
CU	<i>Consolidated Undrained</i>
ELM	<i>Extreme Learning Machine</i>
LM	<i>Levenberg–Marquardt</i>
LS-SVR	<i>Least Squares-Suport Vector Regression</i>
MLP	<i>Multi-Layer Perceptron</i>
MMQO	Método dos Mínimos Quadrados Ordinários
MSE	<i>Mean Square Error</i>
RBF	<i>Radial Basis Function</i>
RSU	Resíduos Sólidos Urbanos
STV	Sólidos Totais Voláteis
SVM	<i>Support Vector Machines</i>

## LISTA DE SÍMBOLOS

$\alpha$	multiplicador de lagrange da primeira restrição
$\beta$	multiplicador de lagrange da segunda restrição
$b$	viés
$c$	intercepto coesivo
$c'$	intercepto coesivo efetivo
$\nabla \mathcal{J}(\mathbf{x}_i, \mathbf{w})$	gradiente de primeira ordem da função custo
$\nabla^2 \mathcal{J}(\mathbf{x}_i, \mathbf{w})$	gradiente de segunda ordem da função custo
$\mathcal{E}$	matriz do erro
$\varepsilon_a$	deformação axial específica
$\xi$	variável de folga
$\mathfrak{F}$	espaço de características
$\phi(\cdot)$	função de ativação
$\phi$	ângulo de atrito
$\phi'$	ângulo de atrito efetivo
$\varphi(\cdot)$	função de mapeamento
$\gamma$	parâmetro de regularização
$\gamma_d$	peso específico seco
$\eta$	taxa de aprendizagem
$\mathbf{H}$	matriz Hessiana
$\mathbf{I}$	matriz identidade
$\mathcal{J}$	função custo
$\mathbf{J}$	matriz Jacobiana
$L$	Lagrangeano
$\Omega$	matriz da função kernel
$\omega$	umidade específica em base seca
$u$	poropressão

$K(\mathbf{x}_i, \mathbf{x}_j)$	função kernel
$\sigma$	parâmetro de abertura da função kernel gaussiana
$\sigma_1$	tensão principal máxima
$\sigma'_1$	tensão principal máxima efetiva
$\sigma_3$	tensão principal mínima
$\sigma'_3$	tensão principal mínima efetiva
$\sigma_1 - \sigma_3$	tensão de desvio
$\sigma'_1 - \sigma'_3$	tensão de desvio efetiva
$\tau$	tensão de cisalhamento
$\mathbf{W}$	matriz de pesos
$\mathcal{X}$	espaço de entrada
$X_{norm}$	matriz da variável normalizada
$\mathbf{x}_i$	vetor de entrada i
$y(\mathbf{x}_i)$	aproximação do vetor de entrada i
$\ \cdot\ $	norma euclidiana



## SUMÁRIO

1	INTRODUÇÃO . . . . .	19
1.1	Contextualização . . . . .	19
1.2	Objetivos . . . . .	20
1.3	Escopo do trabalho . . . . .	20
2	REVISÃO BIBLIOGRÁFICA . . . . .	22
2.1	Características Físicas dos Resíduos Sólidos Urbanos . . . . .	22
2.1.1	<i>Composição Gravimétrica</i> . . . . .	23
2.1.2	<i>Teor de Umidade</i> . . . . .	27
2.1.3	<i>Peso Específico</i> . . . . .	29
2.1.4	<i>Tempo de Decomposição</i> . . . . .	30
2.2	Resistência ao Cisalhamento dos Resíduos Sólidos Urbanos . . . . .	32
2.2.1	<i>Ensaio Laboratoriais</i> . . . . .	34
2.2.2	<i>Critério de Deformação</i> . . . . .	35
2.3	Algoritmos de aprendizado de máquina . . . . .	37
2.4	Redes Neurais: conceitos e histórico . . . . .	39
2.4.1	<i>O Neurônio Biológico</i> . . . . .	40
2.4.2	<i>O Neurônio Artificial</i> . . . . .	41
2.4.3	<i>Características gerais da arquitetura das redes neurais</i> . . . . .	43
2.4.4	<i>A Rede Neural Multilayer Perceptron</i> . . . . .	44
2.4.5	<i>A Rede Neural Extreme Learning Machine</i> . . . . .	49
2.5	O Algoritmo Least Squares Support Vector Regression . . . . .	50
2.5.1	<i>O Problema na forma primal</i> . . . . .	52
2.5.2	<i>O Problema na forma dual</i> . . . . .	53
2.5.3	<i>O Truque de Kernel</i> . . . . .	54
3	METODOLOGIA . . . . .	56
3.1	Coleta dos Dados . . . . .	56
3.1.1	<i>Descrição das variáveis de entrada</i> . . . . .	59
3.1.2	<i>Descrição das variáveis de saída</i> . . . . .	62
3.2	Tratamento dos dados . . . . .	63
3.2.1	<i>Normalização dos dados de entrada</i> . . . . .	63

3.2.2	<i>Análise de Componentes Principais</i> . . . . .	64
3.3	Implementação dos algoritmos de aprendizado de máquina . .	67
3.3.1	<i>Treinamento e validação: Redes Neurais</i> . . . . .	67
3.3.2	<i>Treinamento e validação: Least-Square Support Vector Regression</i> . . . . .	68
4	APRESENTAÇÃO DOS RESULTADOS . . . . .	69
4.1	Implementação dos algoritmos de aprendizado de máquina . .	69
4.1.1	<i>Treinamento e Validação: Redes Neurais</i> . . . . .	69
4.1.2	<i>Redes Neurais Multilayer-Perceptron</i> . . . . .	70
4.1.3	<i>Redes Neurais Extreme Learning Machine</i> . . . . .	80
4.1.4	<i>Treinamento e Validação: Least-Square Support Vector Regression</i> . . . . .	86
4.2	Estudo de caso: aterro sanitário de Santo Tirso . . . . .	92
4.2.1	<i>Características gerais e histórico</i> . . . . .	92
4.2.2	<i>Coleta dos dados</i> . . . . .	94
4.2.3	<i>Caracterização geotécnica do perfil do aterro</i> . . . . .	96
4.2.4	<i>Implementação das redes neurais ELM e MLP</i> . . . . .	98
4.2.5	<i>Análise de estabilidade no Slide</i> . . . . .	101
5	CONCLUSÕES E TRABALHOS FUTUROS . . . . .	105
5.1	Conclusões . . . . .	105
5.2	Sugestão para trabalhos futuros . . . . .	108
	REFERÊNCIAS . . . . .	109
	APÊNDICES . . . . .	115
	APÊNDICE A – scripts da Rede neural MLP . . . . .	115
	APÊNDICE B – scripts da Rede neural ELM . . . . .	119
	APÊNDICE C – scripts do LS-SVR . . . . .	121
	APÊNDICE D – Planta horizontal de localização da área estudada por GOMES (2008) . . . . .	124
	APÊNDICE E – Perfil longitudinal da área estudada por GOMES (2008) . . . . .	125
	ANEXOS . . . . .	125

<b>ANEXO A</b>	– Dados coletados da literatura de ensaios triaxiais: entradas . . . . .	126
<b>ANEXO B</b>	– Dados coletados da literatura de ensaios triaxiais: saídas desejadas . . . . .	141
<b>ANEXO C</b>	– MLP: Resultados das estimativas da amostra total dos dados . . . . .	149
<b>ANEXO D</b>	– ELM: Resultados das estimativas da amostra total dos dados . . . . .	157
<b>ANEXO E</b>	– LS-SVR: Resultados das estimativas da amostra total dos dados . . . . .	165
<b>ANEXO F</b>	– Resultado do aterro de Santo Tirso para a rede neural MLP . . . . .	173
<b>ANEXO G</b>	– Resultado do aterro de Santo Tirso para a rede neural ELM . . . . .	179

# 1 INTRODUÇÃO

Neste capítulo são apresentados o presente contexto das técnicas de estimativas de parâmetros geotécnicos, a motivação do desenvolvimento do trabalho e os objetivos gerais e específicos delineados.

## 1.1 Contextualização

Os resíduos sólidos urbanos são materiais possuidores de comportamento mecânico complexo e difíceis de serem ensaiados. Na tentativa de relacionar a influência dos materiais König e Jessberger (1997) descrevem a resistência característica dos resíduos em função de uma estrutura matricial composta, sendo representada a resistência pela ação das matrizes básica e de reforço.

A caracterização da resistência de cisalhamento dos RSU tem o caráter subjetivo do critério de deformação axial específica, tendo como justificativa a ausência da ruptura física que não é alcançada como nos solos. Os níveis de deformação axial específica relatados na literatura são elevados e a envoltória de Mohr-Coulomb tem grande variedade observável com a diversidade destes níveis.

Nas dificuldades experimentais é apontado por Gomes (2008) a grande complexidade em elaborar um programa de ensaios e a grande quantidade de perda de instrumentos. Nos ensaios de campo e laboratório Carvalho (1999) enumera dentre os obstáculos confrontados a quantidade de material necessário a ser coletado; dimensões dos corpos de provas; dificuldade de molda-los; as condições dos ensaios; tempo de execução e a grande variedade de materiais a ser lidado.

Uma solução reconhecida para representar o comportamento mecânico é a utilização de modelos constitutivos ou empíricos para realização de estimativas. Na utilização de modelos constitutivos Machado *et al.* (2002) assume que a resistência é comandada pelo material fibroso e pastoso, obtendo bons resultados na modelagem do comportamento mecânico. Nos métodos de mais utilizados, Asadi *et al.* (2017) relatou o modelo hiperbólico de Duncan e Chang (1970) como adequado para realização de estimativas em níveis limites de deformação.

O uso do aprendizado de máquina é uma alternativa pouco explorada para estimativa da envoltória e avaliação do comportamento mecânico, apesar de demonstrar

capacidade de realizar regressões com pouco tempo e alto desempenho. Na literatura [Falamaki e Shahin \(2018\)](#) relataram um bom desempenho na utilização de redes neurais dos tipos RBF e MLP, sendo relatados um coeficiente de regressão linear de 0,97 para o intercepto coesivo efetivo e de 0,89 para o ângulo de atrito efetivo.

Dentro do presente contexto, dadas as dificuldades em estabelecer e realizar um programa de ensaios e a demanda de avaliação de aterros sanitários, os algoritmos de aprendizado de máquina são uma solução relevante pela capacidade de aproximação e, comparativamente, pouco desenvolvimento exigido.

## 1.2 Objetivos

O objetivo geral deste trabalho é estimar os parâmetros geotécnicos de intercepto coesivo e ângulo de atrito efetivos, através de dados obtidos da literatura e da utilização de métodos de aprendizado de máquina.

Os objetivos específicos do trabalho são os três apresentados abaixo.

- Obter uma base de dados, representadas pelas propriedades físicas e mecânicas, a partir dos ensaios reunidos da literatura.
- Implementar e avaliar algoritmos de aprendizado de máquina, quanto a adequação ao tamanho da base de dados, tais como, especificamente, MLP; ELM e LS-SVR na estimativa de parâmetros geotécnicos de resistência ao cisalhamento dos RSU.
- Definir dentre as variáveis de entrada e saída, quais funcionam melhores como parâmetros dos algoritmos para uma boa capacidade de generalização dos modelos.

## 1.3 Escopo do trabalho

A presente dissertação é composta de cinco capítulos. No primeiro capítulo são exibidos a contextualização no qual se insere as motivações do trabalho, a descrição dos objetivos gerais e específicos, e o escopo do trabalho.

A revisão bibliográfica é composta de cinco seções. Na primeira seção é exposta a revisão realizada das propriedades físicas dos RSU, sendo descrita sua influência sobre as propriedades mecânicas. Na segunda seção é exibida uma revisão sobre a resistência ao

cisalhamento dos RSU. Na terceira seção é explanado a fundamentação dos métodos de aprendizado de máquina, dando enfoque a utilização como função de aproximação e nas características similares dentre os métodos empregados. Na quarta seção é indicado a teoria e processo de cálculo das diferentes redes neurais implementadas. Na quinta seção é explicada a teoria e procedimento de cálculo do LS-SVR implementado.

A metodologia empregada é representada em três seções, compreendendo a coleta, tratamento dos dados e a implementação dos algoritmos. Na primeira seção é explanado a coleta e representação dos dados extraídos. Na segunda seção é explicada as adequações que antecedem a implementação, visando aperfeiçoar os resultados a serem obtidos. Na terceira seção é descrita a implementação adotada, o procedimento de busca, treinamento e validação das variáveis que compõem os métodos de aprendizado de máquina.

Os resultados apresentados refletem o emprego da metodologia. O capítulo é dividido em 4 seções. Na primeira seção são expostos a exposição detalhada dos ensaios, local de extração dos RSU, bem como a citação dos trabalhos e a descrição das variáveis adotadas como dado de entrada. Na segunda seção é exibido o tratamento de dados aplicados, sendo relatado o intervalo das variáveis e o nível de importância dos dados de entrada. Na terceira seção é exposto o resultado por método de aprendizado de máquina. Na quarta seção é feita uma demonstração da utilização para estimativa do estudo de caso apresentado.

As conclusões dos objetivos são apresentados juntamente com demais sugestões notadas após a aferição dos resultados no quinto capítulo.

As referências, anexos e apêndices são expostos ao final do capítulo de conclusão. Os anexos A e B se referem aos dados de entrada e saídas coletados. Os anexos C, D e E são alusivos aos resultados das estimativas. Os anexos F e G são relativos aos resultados do estudo de caso. Os apêndices A, B e C são referentes aos *scripts* utilizados no *Octave*. Os apêndices D e E são concernentes aos dados da área estudada por [Gomes \(2008\)](#).

## 2 REVISÃO BIBLIOGRÁFICA

Neste capítulo se expõe características dos RSU, sendo relatada a ligação entre suas propriedades físicas e entre os parâmetros de resistência ao cisalhamento. Os métodos de ensaios de RSU são descritos embasando a construção do banco de dados. As técnicas de aprendizado de máquina são apresentadas dando ênfase na sua performance e nas diferenças entre métodos.

Na seção 2.1 é realizada, inicialmente, para cada uma das características uma descrição dos fatores que as influenciam, posteriormente, são expostos os padrões e tendências, através de ensaios e análises realizadas por diversos pesquisadores e, finalmente, sua associação com a resistência ao cisalhamento. Nesta seção, portanto, são descritas a relação entre as características físicas e entre os parâmetros de intercepto coesivo e ângulo de atrito estimados no trabalho.

Na seção 2.2 é exposta a associação entre o nível de deformação e os parâmetros geotécnicos; a descrição dos modelos que representam o comportamento mecânico para RSU; os métodos de medição de campo e laboratório e as características fundamentais dos ensaios triaxiais em RSU. Nesta seção são descritos o comportamento de resistência ao cisalhamento e embasados os critérios de escolha para a construção da base de dados por meio dos ensaios triaxiais.

Na seção 2.3 são apresentados os algoritmos de aprendizado de máquina empregados na estimativa dos parâmetros geotécnicos. Os métodos de treinamento e validação são detalhados extensivamente embasando a escolha dos algoritmos. Nesta seção é elucidada a estrutura do algoritmo, hiperparâmetros dos modelos e sua capacidade de ajuste.

### 2.1 Características Físicas dos Resíduos Sólidos Urbanos

Os RSU são resultantes da constituição de diversos materiais com propriedades físicas e mecânicas distintas. A consequência decorrente de sua composição altamente heterogênea se demonstra através de seus índices físicos, seu potencial de biodegradação e comportamento mecânico. As propriedades físicas dos resíduos, portanto, estão intrinsecamente ligadas.

### 2.1.1 Composição Gravimétrica

A determinação da composição do RSU se faz necessária para identificação dos materiais que o integra e sua influência nas características atribuídas ao resíduo. A composição, normalmente, é atribuída em função do percentual de massa dos resíduos, podendo ser avaliada, também, em função do volume.

A composição gravimétrica tem importância em diversas questões, servindo como uma caracterização inicial aos resíduos, merecendo destaque a influência direta desta nas propriedades mecânicas, índices físicos e tempo de decomposição.

A composição gravimétrica é obtida por meio de uma série de ensaios, sendo necessária a amostragem de grande quantidade de material a ser separado e pesado. Caso o nível de degradação do RSU seja alto, faz-se necessário ensaios de laboratório para determinação dos Sólidos Totais Voláteis (STV).

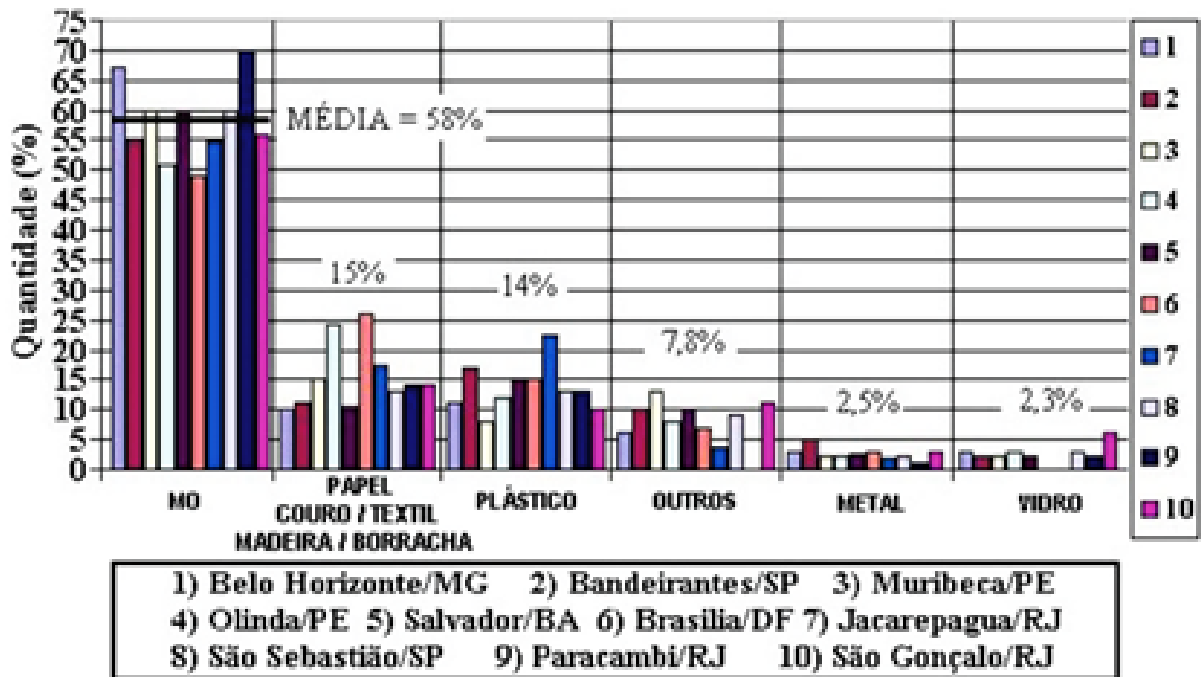
O percentual de matéria orgânica, parcela volátil ainda em decomposição, é definido pela queima da matéria presente, entretanto na prática muitas vezes esta matéria é determinada conjuntamente com a fração pastosa. A determinação da composição varia, também, de acordo com a profundidade do aterro, sendo esta mais uma variável a importante na coleta da amostra.

Na literatura é relatado por [Calle \(2007\)](#) a experiência de pesquisadores em aterros sanitários brasileiros. A constatação é de que na composição dos resíduos há um grande percentual de matéria orgânica, em termos de massa, antes de realizado o pré-tratamento, ficando a média da literatura estudada pelo autor em torno de 60%, enquanto que para o material fibroso foi de 26%.

Nos exemplos são citados por [Calle \(2007\)](#) composições observadas nos aterros em Bandeirantes (SP), por [Machado et al. \(2000\)](#); Muribeca (PE), por [Monteiro et al. \(2001\)](#); Brasília (DF) por [Junqueira \(2000\)](#), Jacarepaguá (SP), por [Borgatto \(2006\)](#); São Sebastião (RJ), por [Calle \(2005\)](#); Paracambi (RJ), por [Schueler \(2005\)](#) e São Gonçalo (RJ), por [Silveira \(2004\)](#) dentre outros. Os altos teores de matéria orgânica, figura 2.1, observados nos aterros brasileiros, portanto, são atribuídos como acima da média e próprios de países em desenvolvimento.



Figura 2.1 – Composição gravimétrica de aterros sanitários



Fonte: (CALLE, 2007).

Os sistemas de classificação tem papel de auxiliar a compreensão da natureza complexa dos RSU, sendo escasso na literatura métodos que orientem sobre sua execução. A ABNT (2004) orienta a classificação dos resíduos na perspectiva de riscos potenciais a saúde pública e meio ambiente. A finalidade da norma brasileira contempla, portanto, apenas, critérios gerenciais de destinação.

Dada a variação significativa dos materiais de resíduos, bem como o número limitado de pesquisadores e profissionais envolvidos na determinação de suas propriedades mecânicas, um sistema de classificação é considerado crucial no desenvolvimento de uma estrutura unificada para a mecânica de resíduos, e, portanto, para nossa aptidão em projetar e operar aterros que representem risco mínimo para o ambiente (LANGER; DIXON, 2004).

Langer e Dixon (2004) visando o controle técnico de aterros realizaram uma avaliação de métodos de classificação descrevendo a proposta e critérios técnicos dos autores citados conforme tabela 2.1. A avaliação realizada visou determinar uma proposta capaz de descrever as propriedades mecânicas de RSU.

Tabela 2.1 – Panorama dos sistemas de classificação existentes

<b>Autor</b>	<b>Tópico chave da classificação</b>	<b>Parâmetros</b>
Turczynski (1988)	Tipo de resíduo	Densidade, parâmetros de cisalhamento, limites de liquidez/plasticidade, permeabilidade
Siegel <i>et al.</i> (1990)	Grupos de Materiais	Parte da composição
Landva e Clark (1990)	Materiais orgânicos e inorgânicos	Degradabilidade (facilmente, lentamente ou não degradável)
Grisolia <i>et al.</i> (1995a)	Grupos de Materiais: degradáveis, inerte e deformáveis	Resistência, deformabilidade e degradabilidade
Kölsch (1996)	Grupos de Materiais	Forma, tamanho
Manassero <i>et al.</i> (1997)	Solossemelhante e outros	Propriedades dos índices
Thomas <i>et al.</i> (1999)	Solossemelhante e não solossemelhante	Grupo de materiais

Fonte: (LANGER; DIXON, 2004).

Segundo Langer e Dixon (2004) um número vasto de sistemas de classificação de engenharia existentes são simplesmente baseados em grupos de materiais (SIEGEL *et al.*, 1990) ou na distinção entre aparência semelhante e não-semelhante ao solo ou a fibra (MANASSERO *et al.*, 1997; THOMAS *et al.*, 1999).

Os sistemas estudados por Langer e Dixon (2004) apresentam desvantagens mencionadas pelos autores quanto ao detalhamento de critérios para uma rigorosa estrutura de classificação. Na revisão realizada é dada ênfase aos trabalhos propostos por Landva e Clark (1990), Kölsch (1996) e Grisolia *et al.* (1995a), sendo exploradas as vantagens dos métodos ao final do trabalho.

No sistema de Landva e Clark (1990) os constituintes dos RSU são divididos em (i) orgânicos e (ii) inorgânicos. Na primeira classe (i) os elementos são, ainda, subdivididos em putrescíveis e imputrescíveis e, na segunda (ii), são divididos em degradáveis ou não degradáveis. No método, são fornecidas informações sobre degradação e potencial de compressibilidade, porém sem acrescentar detalhes sobre a forma ou propriedades

materiais.

O sistema de Kölsch (1996) consiste na divisão de classes pelo tamanho: partículas maiores e menores do que 40mm e forma bidimensional e tridimensional. A proposta do autor é que todos os constituintes dos RSU podem ser caracterizado em grupos de tamanho e forma, sendo divididos em três grupos.

- i)* **DIM 0** - partículas menores de 40 mm e todas as formas;
- ii)* **DIM 1/2** - partículas maiores de 40 mm e formas bidimensionais. (exemplos: formas de fibras, camadas delgadas e folha delgada);
- iii)* **DIM 3** - partículas maiores de 40 mm e formas tridimensionais.
  - 3a.* forma oca e facilmente compressível
  - 3b.* forma oca e dificilmente compressível
  - 3c.* forma sólida e incompressível

A vantagem do sistema proposto é devido ao grande detalhamento das propriedades dos resíduos, sendo compatível com a variedade de constituintes dos RSU. A desvantagem é a necessidade de uma considerável quantidade de dados e a falta de informações sobre potenciais de degradação.

Na proposta de Grisolia *et al.* (1995a) foi definida a influência da composição dos RSU no comportamento mecânico dos resíduos, sendo uma referência bastante empregada na literatura. A proposta consiste na caracterização da composição por classes agrupadas por meio de características comuns.

As características das classes estão atreladas às propriedades mecânicas e ao potencial de degradação. Nesse sistema de classificação os autores estabeleceram três categorias A, B e C, sendo A – Material inerte e estável, B - Material altamente deformável e C – Material facilmente degradável (tabela 2.2).

Tabela 2.2 – Sistema de Classificação por GRISOLIA *et al* (1995)

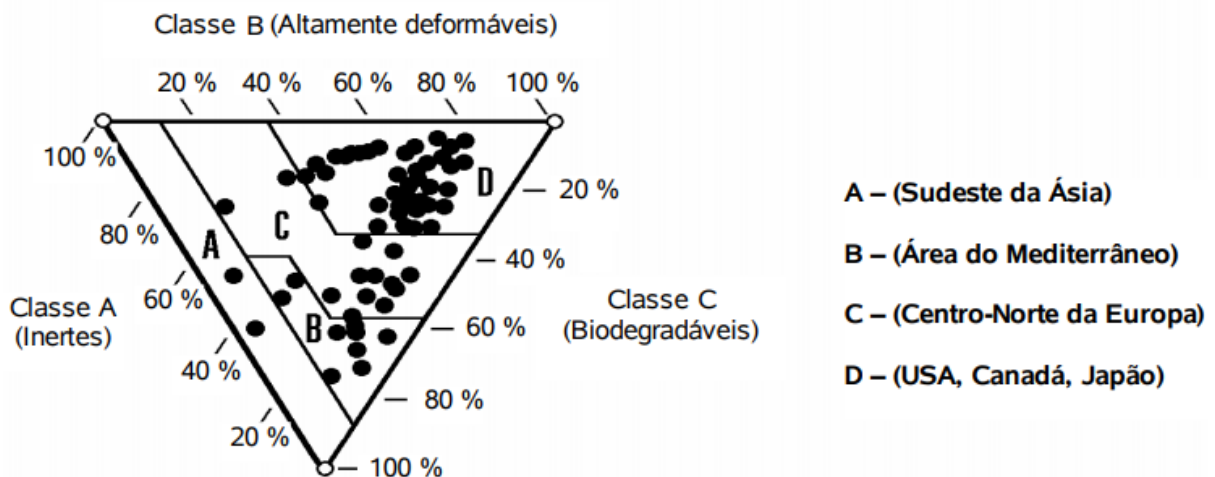
<b>Grupo do Material</b>	<b>Critério de Classificação</b>	<b>Materiais Componentes</b>
A	Material inerte e estável	Metais, vidros, resíduos de demolição e de natureza granular
B	Material altamente deformável	Papéis, plástico, têxteis, borracha
C	Material facilmente degradável	Materiais de origem orgânica, restos de comida, vegetais, etc

Fonte: Autor.

No proposto pelos autores a composição dos materiais em grupo é representada num diagrama triangular, onde cada aresta representa uma das classes. A divisão em classes, através dos constituintes majoritários, nos permite observar características locais e compreender como o comportamento mecânico será governado.

No diagrama da figura 2.2, as amostras classificadas de diferentes regiões definem grupamentos, nas quais podemos estabelecer quais tipos de materiais mais influenciam o comportamento mecânico. Exemplo: as amostras dos resíduos de origem de países como: Estados Unidos, Canadá e Japão (*cluster D*) sofrem menos pelos efeitos da degradação do que resíduos de países do Mediterrâneo (*cluster B*), enquanto estes são, comparativamente, menos deformáveis.

Figura 2.2 – Classificação de RSU pelo diagrama triangular



Fonte: (GRISOLIA *et al.*, 1995a) adaptado por (NASCIMENTO, 2007).

Na perspectiva de Langer e Dixon (2004) a grande vantagem do sistema proposto por Grisolia *et al.* (1995a) são as informações de compressibilidade e degradabilidade dos materiais, porém, um componente pode se encaixar em mais de um dos grupos, por exemplo resíduos alimentares são altamente degradáveis e deformáveis, sendo ignorado também o formato destes constituintes.

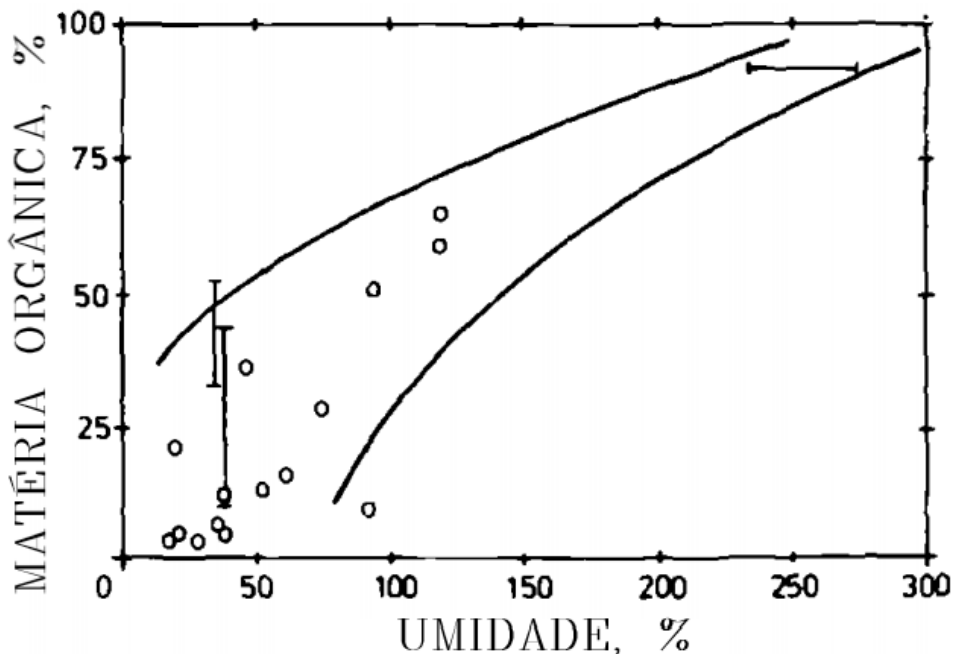
### 2.1.2 Teor de Umidade

O teor de umidade é um índice físico com grande amplitude que exerce importante papel no desenvolvimento da biodegradação, sofrendo forte influência da quantidade de matéria orgânica presente nos RSU. Segundo El-Fadel e Rashed (1997 apud CARVALHO,

1999) o teor de umidade é a variável que mais afeta os processos de biodegradação, pois promove um ambiente aquoso que facilita o transporte de nutrientes e microorganismos, além de diluir os constituintes inibidores do processo.

No aterro, os componentes orgânicos são utilizados como substrato por um número de diferentes microorganismos capazes de estabilizar e de converter a matéria orgânica facilmente degradável em subprodutos (MILLER *et al.*, 1991 apud CARVALHO, 1999). As experiências de ensaios realizados por Landva e Clark (1990), em ensaios de aterros antigos no Canadá, demonstram relações entre a matéria orgânica e umidade (figura 2.3), sendo observada a tendência de aumento exposta, também, por Gomes (2008).

Figura 2.3 – Matéria orgânica × umidade de antigos aterros no Canadá



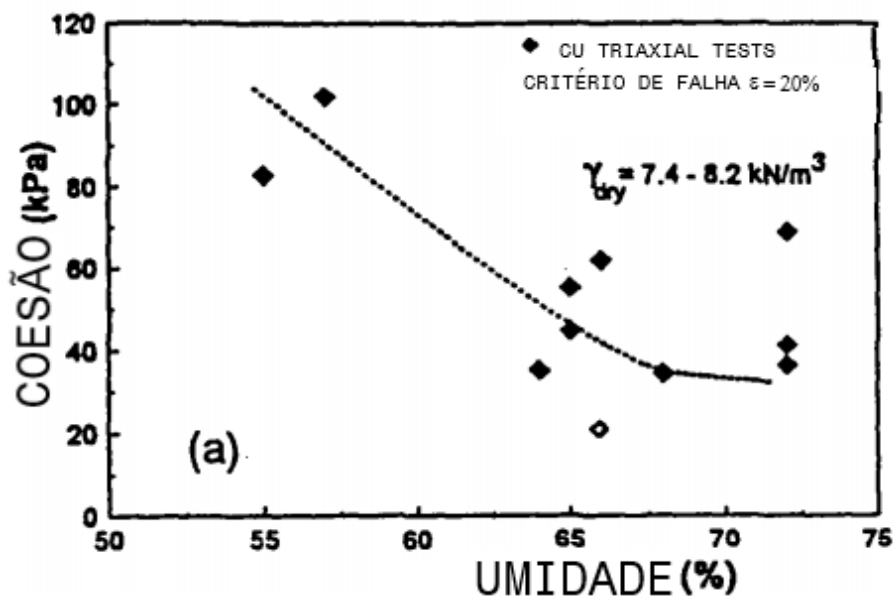
Fonte: Adaptado de (LANDVA; CLARK, 1990).

O teor de umidade também sofre influência de diversas outras variáveis. No estudo de Nascimento (2007) são apontados como elementos preponderantes para a variação do teor de umidade as condições climáticas, o estado de decomposição e a circulação do lixiviado.

A influência da umidade nos valores observados dos parâmetros geotécnicos é relatada por Kockel *et al.* (1999), sendo evidenciado que um aumento no teor de umidade deve levar a uma redução no ângulo de atrito interno. A consequência do enfraquecimento da fibra, portanto, leva à uma importante função do teor de umidade na diminuição da resistência ao cisalhamento.

Gabr e Valero (1995) perceberam nos ensaios realizados, por exemplo, a diminuição da coesão com o aumento da umidade. Por exemplo uma amostra com, aproximadamente, 100 kPa de coesão e 55% de umidade, quando sofre um acréscimo até 72%, a coesão cai para 40 kPa, conforme figura 2.4. Os valores de umidade observados variaram entre 30 a 100% e a idade da amostra dos resíduos entre 15 e 30 anos, sendo explicado, pelos autores, que o efeito do envelhecimento evidencia a tendência da diminuição da coesão efetiva devido à decomposição dos materiais fibrosos e de natureza orgânica presentes.

Figura 2.4 – Efeitos da coesão com o teor de umidade RSU



Fonte: Adaptado de (GABR; VALERO, 1995).

### 2.1.3 Peso Específico

O peso específico *in situ* dos resíduos depende principalmente da composição, esforço de compactação, volume de cobertura diário do solo e teor de umidade. O grau de compactação tem fundamental importância nos RSU devido aos grandes vazios e o alto grau de compressibilidade dos seus constituintes.

Landva e Clark (1990) apresentaram dados de peso específico de resíduos sólidos urbanos obtidos por diferentes autores, com valores variando entre 6,8 e 16,2 KN/m<sup>3</sup> em resíduos *in situ* para aterros no Canadá. Dados apresentados por Kavazanjian *et al.* (1995) de observações coletadas por proprietários e operadores de aterros sanitários, indicaram valores de peso específico de resíduos sólidos urbanos entre 8,6 e 10,2 KN/m<sup>3</sup> para resíduos no local.

Na tabela 2.3 são apresentados valores de peso específicos de resíduos coletados por Oweis (1993). A faixa de valores dos pesos específicos variam de acordo com a compactação, origem e estado dos resíduos, entre intervalos de 2,3 KN/m<sup>3</sup> para lascas de madeiras, até 16,6 KN/m<sup>3</sup> para resíduos de incineração. No trabalho destaca-se a extensa faixa de valores de peso específico para RSU com diferentes graus de compactação, porém é reforçado pelo autor que os resultados foram obtidos para a base de dados de resíduos que possui origens e composições específicas.

Tabela 2.3 – Peso específico do RSU

Forma do Resíduo Sólido Urbano	Peso específico
	KN/m <sup>3</sup>
RSU - compactação moderada a boa	4,7 - 6,3
RSU - compactação ótima a excelente	8,6 - 9,4
RSU - resíduos em fardos	8,6 - 14,1
RSU - aterro ativo com acúmulo de lixiviado	6,6
RSU - aterros antigos	9,7
RSU - originário de poços de ensaio	8,9 - 16,2
RSU - após degradação e recalque	9,9 - 11
Resíduo de incineração recém despejado	7,2 - 12,7
Resíduo de incineração (densidade máxima seca - compactação padrão)	13,5
Resíduo de incineração - velho e recente (densidade <i>in situ</i> )	14,9 - 16,6
Lascas de madeira (seco)	2,3
Lascas de madeira (64% de umidade)	3,8
Composto de folhagens recém despejado	2,6
Composto (40% de umidade)	5,2
Produto final	3,5

Fonte: Adaptado de (OWEIS, 1993).


#### 2.1.4 Tempo de Decomposição

A natureza dos RSU está atrelada à mudança de estado decorrente de processos físico-químicos e biológicos que ocorrem, inicialmente, na parcela orgânica e, posteriormente, nos demais constituintes. A caracterização dos resíduos de forma objetiva, portanto, deveria

ser dada pelo estado de decomposição. As dificuldades em se determinar o estado de decomposição faz com que seja utilizado o tempo como medida ao processo de degradação. A mudança de composição e o nível de alteração dos resíduos rege a resistência ao cisalhamento.

Dentre as relações existentes entre o tempo de decomposição e a composição dos resíduos, observa-se a curva de decaimento em função da idade dos resíduos, apresentada por [Gomes \(2008\)](#) através dos métodos do peróxido de hidrogênio e estufa. O primeiro método é apontado como mais eficaz para medição da quantidade de matéria orgânica oxidável ( $MO_{OXID}$ ). Nos ensaios realizados (figura 2.5) é possível avaliar o ajuste aproximado do tempo de decomposição e da matéria orgânica oxidável, sendo o método empregado, posteriormente, para estabelecer a idade indeterminada de resíduos coletados.

Figura 2.5 – Relação entre teor de matéria orgânica oxidável e a idade dos resíduos



Fonte: Adaptado de ([GOMES, 2008](#)).


A decomposição acarreta na redução da matéria orgânica e no processo de formação do material de reforço. O efeito direto da decomposição produz a mudança de comportamento mecânico. A decomposição de resíduos orgânicos ocasiona o aumento da fração pastosa (solo e resíduos granulares) e a de materiais de reforço (plásticos; borrachas; couros; têxteis e similares) resulta em aumento na quantidade de fibras, sendo atribuído a esta parcela ganho adicional na coesão.

Nos resíduos ensaiados por [Gomes \(2008\)](#) o ângulo de atrito apresentou um ligeiro aumento com a idade, sendo evidenciado pelas deformações axiais mais elevadas para os resíduos mais antigos (figura 2.6). O tempo de decomposição para o intercepto coesivo revela uma diminuição mais nítida, sendo justificada pela autora pelo efeito do desaparecimento da fibra e diminuição do seu tamanho causada pelo envelhecimento



do reforço. De acordo com [Gomes \(2008\)](#) os resultados não permitem concluir uma generalização sobre qual é a influência da idade nos parâmetros. A justificativa reside no fato destes serem obtidos de resíduos distintos, sobre diferentes condições de ensaios.

Figura 2.6 – Efeito do ângulo de atrito com o tempo




Fonte: ([GOMES, 2008](#))

## 2.2 Resistência ao Cisalhamento dos Resíduos Sólidos Urbanos

Os RSU apresentam diferenças no comportamento mecânico tradicional em relação aos diversos tipos de solos. O efeito das características mecânicas é descrito na literatura e relacionado ao processo de formação de fibras que ocorrem no decorrer da decomposição do constituinte do RSU. O comportamento mecânico torna-se, portanto, dependente da interação dos materiais constituintes do RSU.

No representação da resistência ao cisalhamento, [Cardim \(2008\)](#) cita a proposta de divisão dos RSU adotada por [König e Jessberger \(1997\)](#) que consiste numa composição matricial formada por duas estruturas. A primeira é a matriz básica, cuja constituição é, principalmente, de material granular e a segunda a matriz de reforço, cuja formação é dada por materiais capazes de formarem fibras e resistir à tração.

Figura 2.7 – Modelo esquemático da composição dos RSU




Fonte: ([KÖNIG; JESSBERGER, 1997](#)) apaptado por ([CARDIM, 2008](#)).

Kölsch (1995) retrata a representação da interação entre o material e o reforço por meio de quatro etapas. A representação é análoga a um solo reforçado com elementos fibrosos. No material com reforço a resistência cresce com a deformação até um pico a partir do qual sua resistência se reduz.

- Etapa I: inicialmente ocorre a sollicitação da matriz composta apenas com forças de atrito sendo mobilizadas.
- Etapa II: tensionamento crescente tracionam as fibras. A tensão de cisalhamento atinge um valor limite.
- Etapa III: são excedidos a tensão de tração resistente, causando o deslizamento ou rompimento das fibras.
- Etapa IV: o aumento da deformação devido ao cisalhamento é alcançado reduzindo o nível de tensão atribuído ao atrito do resíduo.

Figura 2.8 – Mobilização da coesão e ângulo de atrito com os níveis de deformação



Fonte: (KÖLSCH, 1993) adaptado por (CARDIM, 2008).

A proporção do atrito transferido é, consideravelmente, determinado pela carga normal, tendo aumento linear ao aumento da tensão normal (ângulo de atrito interno,  $\phi$ ). A tração resistente aumenta também com o aumento da tensão normal, por conta da transmissão de forças de tração aperfeiçoadas pela junção das fibras. A associação das forças de tração está restrita à resistência à tração das fibras. Então existe um

determinado nível de tensão normal, onde o valor das forças de tração alcançam um nível máximo. Muitas das interações entre forças de atrito e tração são dependentes das diferentes condições de tensão normal que resultam disto (KÖLSCH, 1995).

### 2.2.1 *Ensaaios Laboratoriais*

Na literatura existe a disposição muitos estudos com dados obtidos por diferentes métodos, porém cada um destes possuem peculiaridades pertinentes às condições de ensaio e aos critérios de ruptura adotados. Na ausência de ruptura física a validade dos parâmetros da envoltória de Mohr-Coulomb deve ser associada ao critério de deslocamento ou ao critério de deformação a depender do tipo de ensaio empregado.

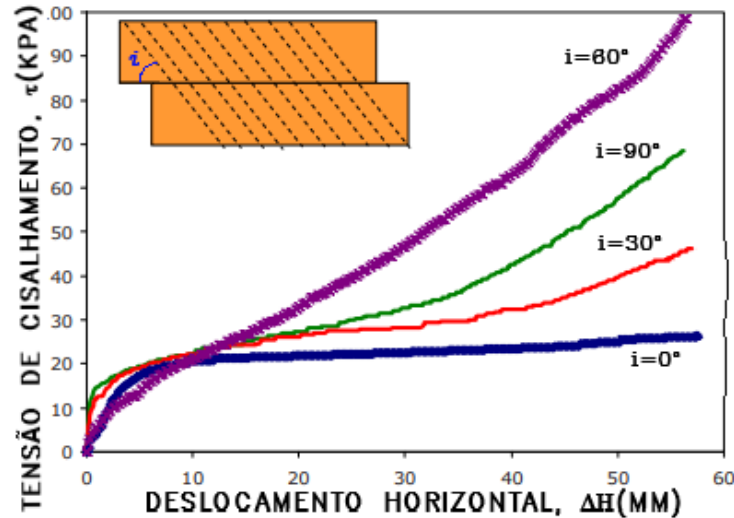
Na revisão dos métodos de ensaios, Dixon e Jones (2005) relacionam a ausência de ruptura ao cisalhamento dos ensaios triaxiais à adoção do critério dos níveis de deformação como referência. O cisalhamento direto é indicado como método mais confiável, sendo recomendada cautela pela grande heterogeneidade dos resíduos.

Bray *et al.* (2009) realizaram experimentos de cisalhamento direto com diferentes ângulos de orientação das fibras, onde pode se perceber nos corpos de prova ensaiados o efeito da disposição do reforço. O ângulo foi mais eficaz no aumento de tensão cisalhante na inclinação de 60°, indicando um comportamento anisotrópico dependente da orientação das fibras (figura 2.9). No experimento realizado o único corpo de prova que não apresentou resistência de pico tinha fibras dispostas a 0° de orientação, sendo observados valores que diferem até 4 vezes entre si.

Dadas as circunstâncias expostas dos ensaios de cisalhamento direto, juntamente com a influência da orientação da fibra, os parâmetros geotécnicos obtidos podem ter resultados bastante divergentes. Na literatura, pelos modelos de comportamento mecânicos estarem mais atrelados à deformação específica, os resultados obtidos de cisalhamento direto podem ter, ainda mais, complexidade de interpretação e comparação.

Os ensaios triaxiais executados nos RSU, normalmente, requerem aparelhagem de grandes dimensões, contudo os princípios dos ensaios são os mesmos dos realizados em solos. Na literatura de triaxiais de RSU os tipos, mais comumente, empregados são os ensaios CD e CU. As condições de drenagem segundo Sanchez-Alciturri *et al.* (1993 apud GOMES, 2008) não são apropriadas quando não-drenada devido ao RSU se encontrarem como não saturados e possuírem alto grau de permeabilidade.

Figura 2.9 – Resistência ao cisalhamento pela direção das fibras



Fonte: Adaptado de (BRAY *et al.*, 2009).


A variação da tensão de confinamento segundo Gomes (2008) para os RSU é relacionada a uma diminuição do ângulo de atrito. A justificativa se embasa na grande deformabilidade da parcela sólida dos RSU. Um acréscimo na tensão confinante intensifica o adensamento, proporcionando uma extensão da área efetiva de apoio. O resultado do aumento da área efetiva de apoio é uma diminuição das tensões nos pontos de contato, ocasionando uma redução destas e a diminuição da resistência de atrito mobilizada.

Os resultados dos triaxiais (figura 2.10) indicam que as fibras do RSU triturado representam um aumento do intercepto coesivo em relação a envoltória da matriz básica, apresentando um ajuste linear adequado para o critério de Mohr-Coulomb. Segundo Manassero *et al.* (1996 apud CARVALHO, 1999) o RSU não apresenta uma envoltória de ruptura significativamente bilinear, como acontece para solos reforçados.

### 2.2.2 Critério de Deformação

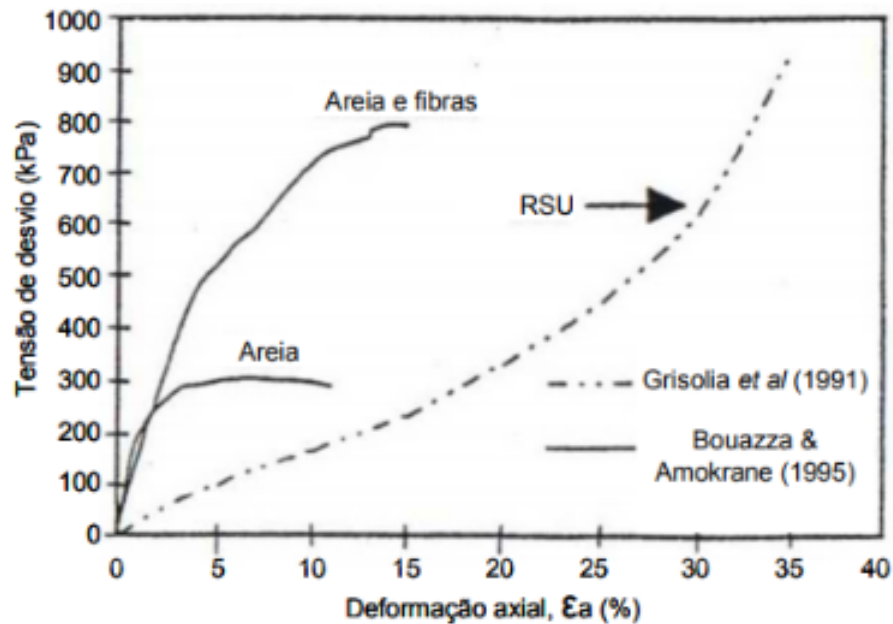
No comportamento de tensão-deformação dos RSU ocorre uma maior mobilização da resistência quanto maior o nível de deformação, sendo documentados acréscimos progressivos para níveis superiores a 45% por Grisolia *et al.* (1995b). O aumento da tensão de cisalhamento sem um pico de resistência, atribuído as fibras presentes, distingue o comportamento mecânico dos resíduos ao dos demais solos, sendo notáveis as diferenças obtidas na literatura pelo progressivo aumento da tensão desviadora (figura 2.11). O efeito destacado é considerado um tipo de endurecimento causado pelo reforço das fibras.

Figura 2.10 – Envoltória de Mohr-Coulomb de diferentes tipos de resíduos



Fonte: (MANASSERO *et al.*, 1996) adaptado por (CARVALHO, 1999).

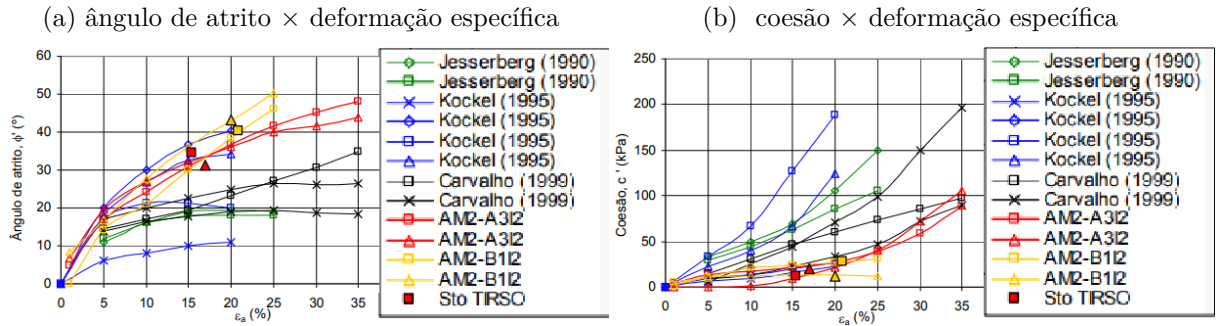
Figura 2.11 – Comparativo tensão desvio e deformação axial: areia, areia e fibras e RSU



Fonte: (MANASSERO *et al.*, 1996) adaptado por (CARVALHO, 1999).

Gomes (2008) realizou um comparativo entre resultados obtidos para o aterro Santo Tirso e autores da literatura. No comparativo o acréscimo das deformações axiais específicas revela o progressivo aumento do ângulo de atrito. O ângulo de atrito é quase totalmente mobilizado para níveis de deformação de 5 a 15% (figura 2.12a), alcançando estabilização, enquanto a coesão é mobilizada de maneira mais nítida para deformações superiores a 10 e 20% sem um valor limite (figura 2.12b).

Figura 2.12 – Comparação entre parâmetros de resistência do RSU



Fonte: Adaptado de (GOMES, 2008).

### 2.3 Algoritmos de aprendizado de máquina

O emprego do aprendizado de máquina baseia-se no processo de aprendizado indutivo, onde deseja-se definir uma função geral que aproxime dados a partir de um conjunto finito de casos, também denominado exemplos. O algoritmo de melhor desempenho de aprendizagem é definido como sendo aquele que consegue extrapolar o conhecimento extraído durante o treinamento para novos exemplos, classificando-os corretamente. A definição de parâmetros, pesos ou arquitetura da rede é determinante para o desempenho do algoritmo.

Se a rede definida for muito pequena, o modelo será incapaz de representar a função desejada. Se a rede for muito grande ela será capaz de memorizar os exemplos dispondo numa relação direta de referência, mas não será capaz de generalizar para exemplos não expostos. Em outras palavras, como qualquer outro modelo estatístico, as redes neurais podem sofrer de *overfitting* se houver muitos parâmetros ou pesos (RUSSELL; NORVIG, 1995).

O treinamento e desempenho de um algoritmo é medido por meio de uma função custo  $\mathcal{J}$  que, normalmente, é utilizada uma função do erro  $\varepsilon$ . Seja um conjunto de  $N$  dados  $\{\mathbf{x}_i, \mathbf{y}_i\}_{i=1}^N$ , onde o  $i$ -ésimo erro é definido por meio da diferença da saída desejada  $\mathbf{y}_i$  e da função de aproximação  $\mathbf{y}(\mathbf{x}_i)$ . A função custo do conjunto de dados é dado como o somatório do erro.

$$\mathcal{J} = \frac{1}{2} \sum_{i=1}^n \|\varepsilon_i\|^2 \quad (2.1)$$

onde  $\|\varepsilon_i\|$  é a norma euclidiana do  $i$ -ésimo vetor de erro e a expressão representa a soma dos quadrados dos resíduos. A expressão pode ser dada diretamente pela função de

aproximação e da saída desejada, passando a seguinte forma.

$$\mathcal{J} = \frac{1}{2} \sum_{i=1}^n \|\mathbf{y}_i - \mathbf{y}(\mathbf{x}_i)\|^2 \quad (2.2)$$

Seja os dados de entrada  $\mathbf{X} \in \mathbb{R}^{n \times p}$  e suas saídas  $\mathbf{Y} \in \mathbb{R}^{n \times q}$ , onde  $n$  representa o número de observações,  $p$  e  $q$  são as dimensões, respectivamente, dispostas nas colunas das matrizes de entrada e saída. No processo de aprendizagem são definidos os pesos da função  $\mathbb{R}^{n \times p} \mapsto \mathbb{R}^{n \times q}$  que aproxima as saídas e minimiza a função custo. Supondo uma relação linear entre variáveis de entrada e saída, podemos expressar as  $n$  aproximações  $\mathbf{y}(\mathbf{x}_i)$  como um sistema de equações entre vetores.

$$\begin{cases} \mathbf{y}(\mathbf{x}_1) = \mathbf{w}_0 + \mathbf{w}_1 x_{11} + \mathbf{w}_2 x_{12} + \dots + \mathbf{w}_p x_{1p} \\ \mathbf{y}(\mathbf{x}_2) = \mathbf{w}_0 + \mathbf{w}_1 x_{21} + \mathbf{w}_2 x_{22} + \dots + \mathbf{w}_p x_{2p} \\ \vdots \\ \mathbf{y}(\mathbf{x}_n) = \mathbf{w}_0 + \mathbf{w}_1 x_{n1} + \mathbf{w}_2 x_{n2} + \dots + \mathbf{w}_p x_{np} \end{cases} \quad (2.3)$$

As equações são expressas de maneira compactas, em negrito, por vetores linhas. Logo pesos, entradas e saídas passam a ser expressos como:  $\mathbf{w}_0 = [w_{01}, w_{02}, \dots, w_{0q}]$ ,  $\mathbf{w}_1 = [w_{11}, w_{12}, \dots, w_{1q}]$ ,  $\dots$ ,  $\mathbf{w}_p = [w_{p1}, w_{p2}, \dots, w_{pq}]$ ,  $\mathbf{y}_1 = [y_{11}, y_{12}, \dots, y_{1q}]$ ,  $\mathbf{y}_2 = [y_{21}, y_{22}, \dots, y_{2q}]$ ,  $\dots$ ,  $\mathbf{y}_n = [y_{n1}, y_{n2}, \dots, y_{nq}]$ . Expressando as saídas em função do erro obtido na aproximação  $\boldsymbol{\varepsilon}_i = \mathbf{y}_i - \mathbf{y}(\mathbf{x}_i)$ , resultando em  $\mathbf{y}_i = \boldsymbol{\varepsilon}_i + \mathbf{y}(\mathbf{x}_i)$ .

$$\begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \\ \vdots \\ \mathbf{y}_n \end{bmatrix} = \begin{bmatrix} \boldsymbol{\varepsilon}_1 \\ \boldsymbol{\varepsilon}_2 \\ \vdots \\ \boldsymbol{\varepsilon}_n \end{bmatrix} + \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix} \begin{bmatrix} \mathbf{w}_0 \\ \mathbf{w}_1 \\ \vdots \\ \mathbf{w}_p \end{bmatrix} \quad (2.4)$$

onde as equações rearranjadas na matriz podem, ainda, ser expandidas nos elementos da matriz abaixo:

$$\begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1q} \\ y_{21} & y_{22} & \cdots & y_{2q} \\ \vdots & \vdots & \ddots & \vdots \\ y_{n1} & y_{n2} & \cdots & y_{nq} \end{bmatrix} = \begin{bmatrix} \varepsilon_{11} & \cdots & \varepsilon_{1q} \\ \varepsilon_{21} & \cdots & \varepsilon_{2q} \\ \vdots & \ddots & \vdots \\ \varepsilon_{1q} & \cdots & \varepsilon_{nq} \end{bmatrix} + \begin{bmatrix} 1 & x_{11} & x_{12} & \cdots & x_{1p} \\ 1 & x_{21} & x_{22} & \cdots & x_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \cdots & x_{np} \end{bmatrix} \begin{bmatrix} w_{01} & w_{02} & \cdots & w_{0q} \\ w_{11} & w_{12} & \cdots & w_{1q} \\ \vdots & \vdots & \ddots & \vdots \\ w_{p1} & w_{p2} & \cdots & w_{pq} \end{bmatrix} \quad (2.5)$$

Reescrevendo o sistema de equações em (2.5) de forma compacta, chega-se à seguinte expressão matricial:

$$\mathbf{Y} = \mathcal{E} + \mathbf{XW} \quad (2.6)$$

A determinação dos pesos e limiares finaliza o treinamento de um algoritmo de aprendizado de máquina. Nas equações (2.4) a (2.6) temos uma demonstração do Método dos Mínimos Quadrados Ordinários (MMQO) um método de regressão estatística que serve como base de diversos modelos.

## 2.4 Redes Neurais: conceitos e histórico

As redes neurais são um método de aprendizado de máquina que faz uso da analogia do cérebro humano e da transmissão do impulso elétrico pelo neurônio biológico. As funções e estruturas do neurônio biológico são empregadas na representação do neurônio artificial que constitui uma rede neural. A vantagem da utilização do método reside na capacidade de aprendizagem e generalização reproduzindo boas soluções de aproximação.

O projeto de uma rede neural é motivado pela analogia com o cérebro, que é a prova viva de que o processamento paralelo tolerante a falhas não só é fisicamente possível, mas também rápido e poderoso. Os neurobiólogos procuram as redes neurais (artificiais) como uma ferramenta de pesquisa para a interpretação de fenômenos neurobiológicos. Por outro lado, os engenheiros buscam na neurobiologia novas idéias para resolver problemas mais complexos do que aqueles baseados em técnicas convencionais de design de conexões eletrônicas (HAYKIN, 2008).



### 2.4.1 O Neurônio Biológico

McCulloch e Pitts (1943) foram os pioneiros a descrever e representar a analogia do neurônio biológico. No trabalho de McCulloch e Pitts (1943) a utilização da analogia é poderosa devido ao caráter definitivo da atividade nervosa que pode ser relacionada com a lógica proposicional, sendo desta forma adotados a descrição da estrutura e função do neurônio biológico como uma máquina computacional.

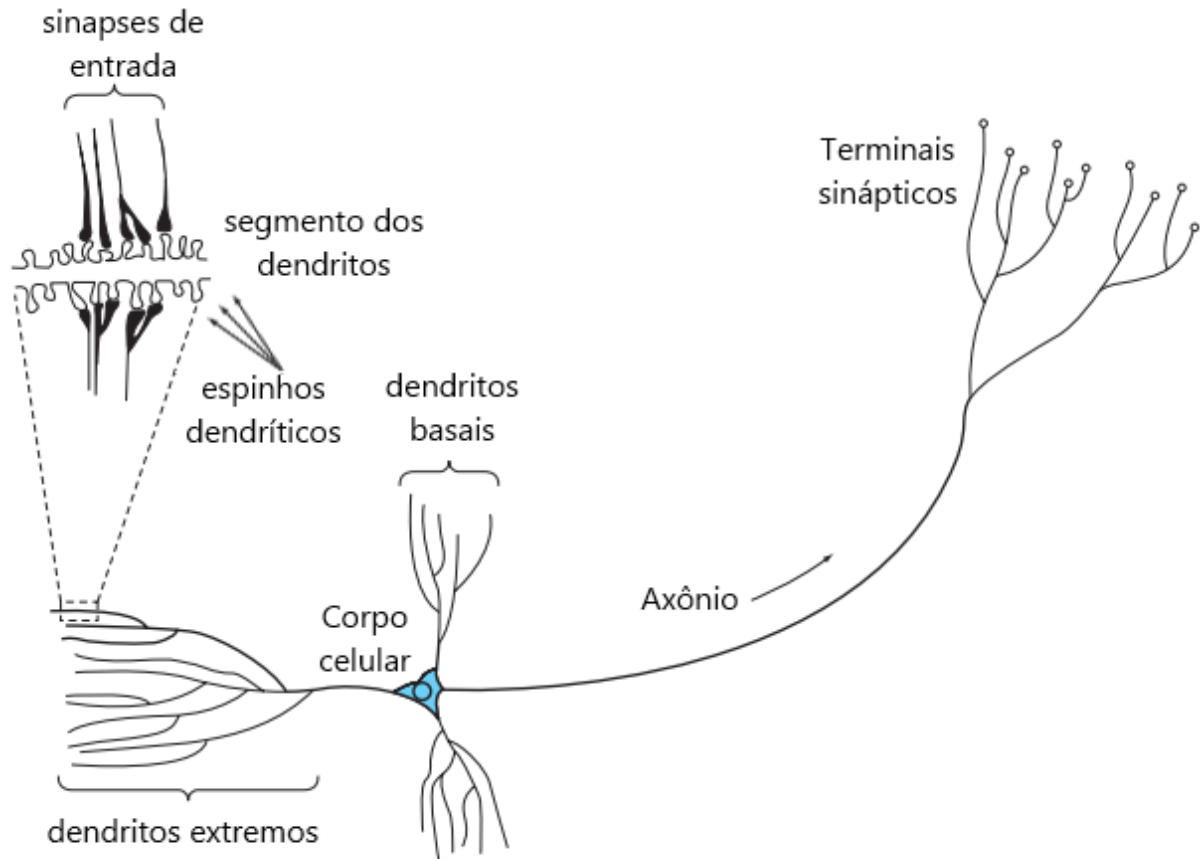
A neurofisiologia teórica se embasa em certas premissas principais. O sistema nervoso é uma rede de neurônios, cada um tendo um corpo celular e um axônio. As adjunções, ou sinapses, estão sempre entre axônios de um neurônio e o corpo celular de outro. A qualquer momento um neurônio tem um limiar, cuja a excitação tem que exceder para dar início a um impulso. Isto, exceto pelo fato e momento de ocorrência, é estabelecido pelo neurônio, não pela excitação. Do ponto de excitação, o impulso é propagado por todo o neurônio (MCCULLOCH; PITTS, 1943).

O neurônio biológico pela sua vasta variedade de formas e funções é analisado de maneira fracionada, funcional e estrutural com as características e papéis desempenhados na transmissão do impulso nervoso.

- **Dendritos:** são as áreas receptoras do estímulo ou sinal de entrada. Os sinais de entradas são recebidos pelas terminações denominadas espinhos dendríticos e retransmitidos por todo o neurônio, geralmente, como pulsos rápidos de tensão.
- **Soma ou corpo celular:** é a parte responsável pelo processamento da informação envolvida no sinal elétrico. Os pulsos conduzidos pelos axônios representam o potencial de ação ou picos que são produzidos, sendo responsável pela propagação do sinal para cada neurônio, ou inibidos no corpo celular.
- **Axônio:** é a estrutura responsável por conduzir o impulso elétrico. Ele tem uma forma prolongada e esbelta, sendo reconhecido pela alta resistência elétrica e elevada capacitância.
- **Sinapses ou terminais sinápticos:** são estruturas que intermediam os contatos entre os neurônios. As excitações entre sinapses acontecem na direção das terminações dos axônios e o corpo celular. A sinapse realiza a conversão de um sinal elétrico pré-sináptico.

Segundo [Haykin \(2008\)](#) neurônios tem uma grande variedade de formas e tamanhos em diferentes partes do cérebro. A figura 2.13 ilustra a forma de uma célula piramidal que é um dos tipos mais comuns de neurônios corticais.

Figura 2.13 – Neurônio biológico



Fonte: Adaptado de ([HAYKIN, 2008](#)).

#### 2.4.2 O Neurônio Artificial

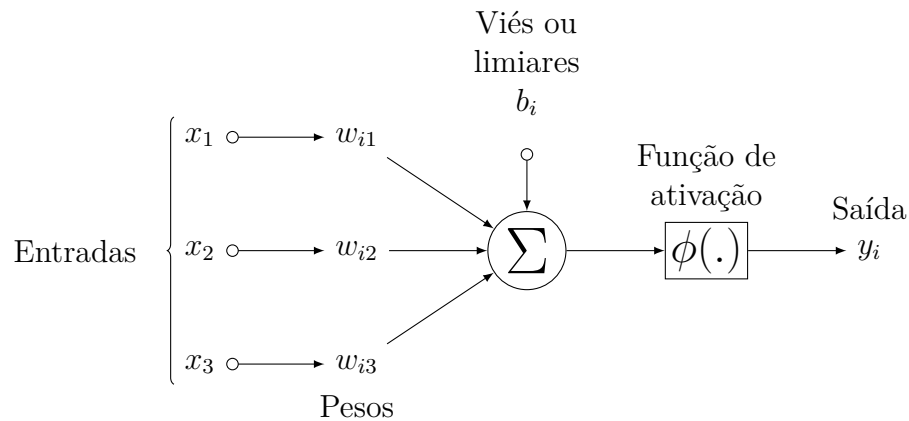
[McCulloch e Pitts \(1943\)](#) através das definições do neurônio biológico definiram o primeiro modelo do neurônio artificial, posteriormente aprimorada por [Rosenblatt \(1958\)](#) com a inclusão de uma regra de aprendizagem. O neurônio artificial denominado perceptron simples é uma unidade de processamento de informação com pesos e limiares definidos por:

- **Pesos sinápticos:** eles são os pesos ou elos de ligação entre cada uma das entradas e um determinado neurônio. Cada neurônio tem um número de pesos sinápticos correspondente a cada um dos sinais de entrada.
- **Viés ou limiar:** é o valor a ser somado, após o processo de multiplicação

dos pesos do neurônio e os sinais de entrada.

- **Função de ativação:** é responsável por determinar a resposta desejada do neurônio.

Figura 2.14 – Neurônio artificial



Fonte: Autor.

O estímulo de entrada para um neurônio artificial  $i$  é propagado pela multiplicação dos pesos sinápticos ( $w_{i1}, w_{i2}, w_{i3}$ ) pelas entradas ( $x_1, x_2, x_3$ ), sendo realizado a soma de um viés  $b_i$  ao cálculo que aumenta ou reduz a ativação do neurônio. A representação da transmissão do impulso elétrico é definida pelo processo de cálculo da equação (2.7).

$$u_i = b_i + \sum_{j=1}^3 w_{ij}x_j \quad (2.7)$$

A saída do neurônio  $y_i$  é o resultante da sua ativação  $\phi(\cdot)$  que representa a resposta conduzida ao impulso elétrico, sendo calculada por:

$$y_i = \phi(u_i) \quad (2.8)$$

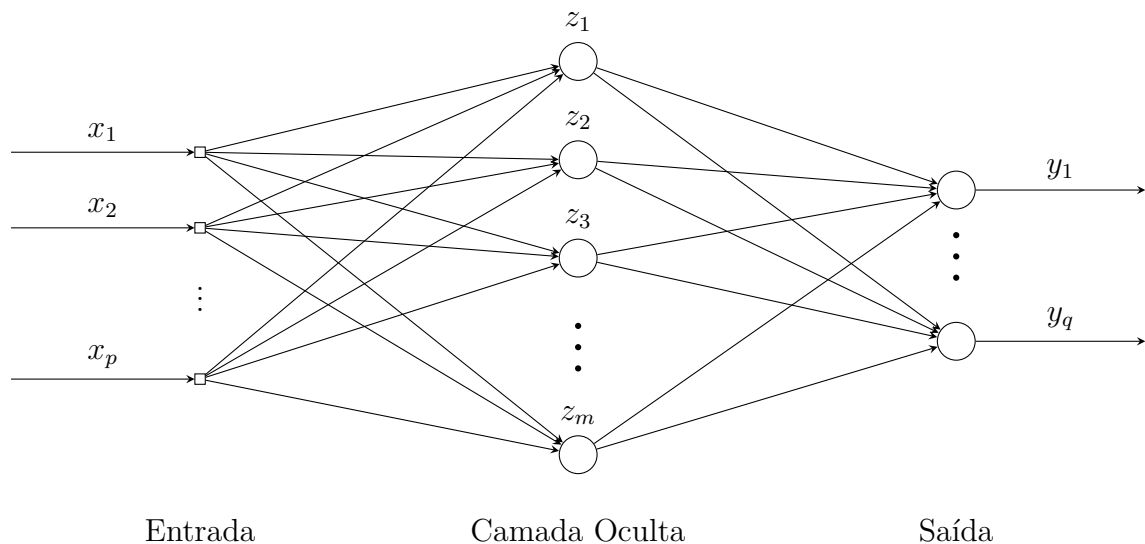
A ativação dos neurônios utilizada em mapeamento de entrada-saída é representada, usualmente, por meio de uma função diferenciável e não-linear. As funções usuais são a sigmóide logística e a tangente hiperbólica, sendo definidas, respectivamente, dentro do intervalo de  $[0,1]$  e  $[-1,1]$ .

$$\text{funções de ativação} \begin{cases} \text{Sigmóide logística: } \phi(u_i) = \frac{1}{1 + e^{-u_i}} \\ \text{Tangente hiperbólica: } \phi(u_i) = \frac{1 - e^{-u_i}}{1 + e^{-u_i}} \end{cases} \quad (2.9)$$

### 2.4.3 Características gerais da arquitetura das redes neurais

O modelo estrutural básico de uma rede neural é representado por nós receptores responsáveis pela condução dos estímulos de entrada, neurônios que também são denominados nós de computação e os pesos sinápticos entre camadas que direcionam o sinal de entrada. A distribuição dos neurônios é realizada somente nas camadas ocultas e de saída. A representação funcional é realizada por meio de um gráfico de fluxo de sinais e a forma como o estímulo se propaga determina o tipo de rede neural, sendo denominada como *feedforward* toda a rede no qual ele é estritamente no sentido progressivo figura 2.15 .

Figura 2.15 – Representação de uma rede neural *feedforward* com uma camada oculta



Fonte: Autor.

Um vetor coluna composto pelas entradas  $(x_1, x_2, \dots, x_p)$  conduz um estímulo que pode ser definido matricialmente para toda a camada segundo a equação (2.10).

$$\mathbf{u}^{(i)} = \mathbf{x}\mathbf{W}^{(i)} \quad (2.10)$$

O sinal é propagado resultando na ativação dos neurônios da camada oculta  $(z_1, z_2, z_3 \dots, z_m)$  representado por:

$$\mathbf{z} = \phi(\mathbf{x}\mathbf{W}^{(i)}) \quad (2.11)$$

A propagação do sinal de entrada segue a fórmula exposta pelas equações (2.7) e (2.8), no entanto a saída do neurônio oculto é recebido como continuidade ao impulso

elétrico para a camada seguinte. O resultado analogamente ao obtido para a camada oculta é dado na forma de matriz pela equação (2.12).

$$\mathbf{u}^{(ii)} = \mathbf{z}\mathbf{W}^{(ii)} \quad (2.12)$$

O resultado final  $(y_1, \dots, y_q)$  é o decorrente da ativação dos neurônios da camada de saída, sendo obtido na forma de matriz por:

$$\mathbf{y} = \phi(\mathbf{z}\mathbf{W}^{(ii)}) \quad (2.13)$$

onde  $\mathbf{W}^{(i)}$ ,  $\mathbf{W}^{(ii)}$  e  $\mathbf{u}^{(i)}$ ,  $\mathbf{u}^{(ii)}$  representam, respectivamente, os pesos sinápticos e o estímulo propagado da camada a qual se referem.

#### 2.4.4 A Rede Neural Multilayer Perceptron

A rede MLP é uma classe de redes neurais com uma ou múltiplas camadas ocultas que se distingue em relação ao perceptron simples pela capacidade de produzir mais de um resultado para a camada de saída. A rede neural segundo [Haykin \(1998\)](#) é essencialmente uma composição de alto nível de conectividade determinada pelos pesos sinápticos, neurônios dispostos em camadas e a inclusão de uma função de ativação não linear e diferenciável.

Segundo [Russell e Norvig \(1995\)](#) as redes MLP não foram exploradas no princípio de sua concepção pela complexidade em representar a contribuição dos erros dos pesos sinápticos que conectam entradas e unidades ocultas, sendo mais difícil determinar o sinal de erro para elas.

O truque é avaliar a causa de um erro e dividi-lo entre os pesos contribuintes. Em perceptrons, isto é fácil, porque existe apenas um peso entre cada entrada e a saída, mas em redes com várias camadas, há muitos pesos conectando cada entrada a uma saída, e cada um desses pesos contribui para mais de uma saída ([RUSSELL; NORVIG, 1995](#)).

A rede MLP se diferencia dentre as demais redes neurais pelo emprego do algoritmo de aprendizagem, sendo o mais usual o *error backpropagation*. Segundo [Russell e Norvig \(1995\)](#) o algoritmo backpropagation é uma forma de distribuir a contribuição de cada peso, sendo minimizado o erro entre a saída desejada e a saída computada pela rede.

O algoritmo de aprendizagem *error backpropagation* é utilizado, juntamente com métodos baseados em gradiente, como procedimento de ajuste dos pesos em redes


neurais, sendo inicialmente idealizado por Bryson e Ho (1969). O processo de ajuste mais aplicado é o proposto por Rumelhart *et al.* (1986) e tem dois sentidos, sendo alterados todos os pesos camada a camada.

O procedimento ajusta repetidamente os pesos das conexões da rede de forma a minimizar a diferença medida entre o vetor de saída da rede e o vetor de saída desejado. Como resultado do ajuste de pesos, unidades 'ocultas' internas que não compõem a entrada ou saída, representam características importantes do domínio da tarefa e as regularidades presentes nelas são captadas pelas interações destas (RUMELHART *et al.*, 1986).

O método de aprendizagem considera a propagação de dois tipos de sinais na rede, sendo o primeiro os sinais de entrada, equivalente aos estímulos transmitidos pela camada, e o segundo os sinais de erro computados em cada neurônio. A propagação segue dois sentidos representado em duas fases figura 2.16. As fases são definidas por Haykin (1998) como abaixo:

- i*) Na fase *forward*, os pesos sinápticos da rede são fixos e o sinal de entrada é propagado através da rede, camada por camada, até atingir a saída. Assim, nesta fase, as mudanças são confinadas aos potenciais de ativação e às saídas dos neurônios da rede.
- ii*) Na fase *backward*, um sinal de erro é produzido pela comparação da saída da rede com uma resposta desejada. O sinal de erro resultante é propagado através da rede, novamente camada por camada, mas desta vez a propagação é feita na direção *backward*. Nesta segunda fase, são feitos ajustes sucessivos no pesos sinápticos da rede. Cálculo dos ajustes para a camada de saída é simples, mas é muito mais desafiador para as camadas ocultas

Figura 2.16 – Representação do sentido das fases *forward* e *backward*



Fonte: Autor.

O sinal de entrada propagado de um neurônio *i* na camada de saída numa

iteração  $t$ , denominada por *epoch*, é dada por:

$$u_i(t) = b_i(t) + \sum_{j=1}^m w_{ij}(t)z_j(t) \quad (2.14)$$

onde  $m$  representa a dimensão dos vetores de entrada e  $z_j(t)$  a ativação do neurônio da camada oculta. O resultado leva ao cálculo do neurônio da camada saída segundo a equação (2.15).

$$y_i(t) = \phi(u_i(t)) \quad (2.15)$$

O ajuste dos pesos sinápticos é realizado otimizando-se a soma dos mínimos quadrados, segundo a função custo na forma (2.1) e (2.2). O ajuste dos pesos  $w_{ij}(t)$  para o  $i$ -ésimo neurônio da camada de saída é proporcional ao gradiente da função custo, sendo expresso segundo a regra da cadeia, pelo procedimento abaixo:

$$\frac{\partial \mathcal{J}(t)}{\partial w_{ij}(t)} = \frac{\partial \mathcal{J}(t)}{\partial \varepsilon_i(t)} \frac{\partial \varepsilon_i(t)}{\partial y_i(t)} \frac{\partial y_i(t)}{\partial u_i(t)} \frac{\partial u_i(t)}{\partial w_{ij}(t)} \quad (2.16)$$

onde o gradiente local da camada de saída é a parcela  $\delta_i(t)$  contida na função e representado segundo (2.17).

$$\delta_i(t) = \frac{\partial \mathcal{J}(t)}{\partial \varepsilon_i(t)} \frac{\partial \varepsilon_i(t)}{\partial y_i(t)} \frac{\partial y_i(t)}{\partial u_i(t)} \quad (2.17)$$

Os pesos sofrem uma atualização para a próxima *epoch* utilizando o método do gradiente descendente, seguindo a regra geral da equação (2.18), onde  $\eta$  representa a taxa de aprendizagem e  $t$  a iteração.

$$w_{ij}(t+1) = w_{ij}(t) - \eta \frac{\partial \mathcal{J}(t)}{\partial w_{ij}(t)} \quad (2.18)$$


O ajuste dos pesos dos neurônios das camadas anteriores segue os mesmos princípios para a camada de saída, porém exige que se prossiga a expansão da regra da cadeia da equação (2.16). O sinal de erro computado é obtido recursivamente com a propagação do gradiente local do neurônio na camada de saída até o neurônio da referida camada oculta que deseja-se atualizar os pesos.

Demos algumas razões sugestivas para que as equações de retropropagação sejam razoáveis. Acontece que as equações também podem ser dadas uma interpretação

muito simples como um método para superfície de erros que realiza descida por gradiente no espaço dos pesos. Neste caso, o gradiente está sobre a superfície do erro: a superfície que descreve o erro em cada exemplo como uma função de todos os pesos na rede neural (RUSSELL; NORVIG, 1995).

O método do gradiente tem convergência assegurada, entretanto existem problemas, relacionados a convergência e eficiência computacional. A busca em gradiente na superfície do erro pelo ponto de mínimo global, figura 2.17, que seja solução para o problema de mínimos quadrados não é necessariamente alcançada.

Figura 2.17 – Busca em gradiente na superfície do erro



Fonte: Autor

Haykin (2008) define o método de *Levenberg–Marquardt* (LM) como um ajuste entre dois métodos. O primeiro é o método de Newton que tem tendência a convergir rapidamente quando próximo de um ponto de mínimo local ou global. O segundo é o gradiente descendente que tem convergência assegurada quando o passo tem tamanho apropriado, porém sua convergência é muito lenta.

O método é uma técnica de otimização de segunda ordem que se utiliza do gradiente da função de aproximação  $\mathbf{y}(\mathbf{x}_i, \mathbf{w})$  e da aproximação da matriz Hessiana  $\mathbf{H}$  para acelerar a convergência. As derivadas parciais de primeira e segunda ordem da função



custo podem ser definidos segundo a expressão (2.19).

$$\mathcal{J}(\mathbf{w}) = \frac{1}{2n} \sum_{i=1}^n [y_i - \mathbf{y}(\mathbf{x}_i, \mathbf{w})]^2 \quad (2.19)$$

$$\mathbf{g}(\mathbf{w}) = \frac{\partial \mathcal{J}(\mathbf{w})}{\partial \mathbf{w}} = -\frac{1}{n} \sum_{i=1}^n [y_i - \mathbf{y}(\mathbf{x}_i, \mathbf{w})] \frac{\partial \mathbf{y}(\mathbf{x}_i, \mathbf{w})}{\partial \mathbf{w}} \quad (2.20)$$

$$\begin{aligned} \mathbf{H}(\mathbf{w}) = \frac{\partial^2 \mathcal{J}(\mathbf{w})}{\partial \mathbf{w}^2} &= \frac{1}{n} \sum_{i=1}^n \left[ \frac{\partial \mathbf{y}(\mathbf{x}_i, \mathbf{w})}{\partial \mathbf{w}} \right] \left[ \frac{\partial \mathbf{y}(\mathbf{x}_i, \mathbf{w})}{\partial \mathbf{w}} \right]^\top \\ &\quad - \frac{1}{n} \sum_{i=1}^n [y_i - \mathbf{y}(\mathbf{x}_i, \mathbf{w})] \frac{\partial^2 \mathbf{y}(\mathbf{x}_i, \mathbf{w})}{\partial \mathbf{w}^2} \end{aligned} \quad (2.21)$$

No processo de cálculo ignora-se o segundo termo da expressão (2.21) pela complexidade e custo computacional envolvido no seu cálculo. Segundo [Haykin \(2008\)](#) o uso dessa aproximação é justificada quando o algoritmo de Levenberg-Marquardt está operando nas proximidades de um mínimo local ou global.

$$\mathbf{H}(\mathbf{w}) \approx \frac{1}{n} \sum_{i=1}^n \left[ \frac{\partial \mathbf{y}(\mathbf{x}_i, \mathbf{w})}{\partial \mathbf{w}} \right] \left[ \frac{\partial \mathbf{y}(\mathbf{x}_i, \mathbf{w})}{\partial \mathbf{w}} \right]^\top \quad (2.22)$$

A regra geral de atualização dos pesos do método utiliza-se da aproximação da Hessiana e da derivada de primeira ordem resultando em:

$$\mathbf{w}(t+1) = \mathbf{w}(t) - [\mathbf{H}]^{-1} \mathbf{g} \quad (2.23)$$

O problema passa ser a invertibilidade da matriz  $[\mathbf{H}]^{-1}$  e a propriedade da matriz ser definida positiva. A solução proposta por [Levenberg \(1944\)](#) foi o somatório de um termo expresso por  $\lambda \mathbf{I}$  a aproximação da matriz Hessiana, onde  $\lambda$  é um parâmetro regularizador e  $\mathbf{I}$  é a matriz identidade.

$$\mathbf{w}(t+1) = \mathbf{w}(t) - [\mathbf{H} + \lambda \mathbf{I}]^{-1} \mathbf{g} \quad (2.24)$$

O parâmetro de regularização  $\lambda$  tem seu valor alterado a cada iteração, sendo reduzido por uma ordem de 10 ou similar se a função custo diminui ou, caso contrário, aumentado. O método exige alguns cuidados quanto a sucessivos aumentos realizados no parâmetro de regularização por reduzir o peso da informação contida na aproximação  $[\mathbf{H}]^{-1}$ . A solução proposta por [Marquardt \(1963\)](#) substitui a matriz identidade pela diagonal da estimativa inicial.

$$\mathbf{w}(t+1) = \mathbf{w}(t) - [\mathbf{H} + \lambda \text{diag} \mathbf{H}]^{-1} \mathbf{g} \quad (2.25)$$

### 2.4.5 A Rede Neural Extreme Learning Machine

O ELM é uma rede neural do tipo *feedforward* com uma camada oculta ou *SLFN*. A diferença da rede ELM relativa a MLP está no ajuste apenas dos neurônios da camada de saída e na não utilização do algoritmo *error backpropagation* no processo de aprendizagem.

O algoritmo de aprendizagem popular, Segundo Huang *et al.* (2004), utilizado em redes *feedforward*, é o *backpropagation*, em que o gradiente é computado e propagado da saída para a entrada. Existem vários problemas com a aprendizagem nos algoritmos *error backpropagation*, sendo enumerados pelo autor por:

- i) Quando a taxa de aprendizagem é muito pequena o algoritmo converge muito lentamente, entretanto quando grande ele se torna instável e diverge.
- ii) A Presença de pontos de mínimos locais impacta a superfície do erro. Torna indesejável que a aprendizagem do algoritmo pare em um ponto de mínimo local, se for muito distante do ponto de mínimo global.
- iii) As redes neurais podem sofrer de *over-training* pela utilização do algoritmo e obter pior performance de generalização. Validação e critérios de parada adequados podem ser necessários na minimização da função custo.
- iv) Métodos de aprendizagem baseados em gradiente são muito custosos relativo ao tempo na maioria dos casos.

O ELM é uma proposta alternativa de Huang *et al.* (2004) para resolver os problemas observados da rede MLP. O algoritmo é capaz de aproximar qualquer função contínua sem alterar os pesos e vieses da camada oculta, se pelo menos a função de ativação for infinitamente diferenciável. Os autores esclarecem na sua demonstração que o método tende a garantir a melhor performance de generalização na maioria dos casos.

A determinação dos pesos da camada oculta é gerada de maneira aleatória. O valor destes pesos de entrada são fixos durante todo o processo de aprendizagem.

$$\mathbf{W} = \begin{bmatrix} w_{01} & w_{02} & \cdots & w_{0m} \\ w_{11} & w_{12} & \cdots & w_{1m} \\ \vdots & \vdots & \ddots & \vdots \\ w_{p1} & w_{p2} & \cdots & w_{pm} \end{bmatrix} = \begin{bmatrix} \mathbf{w}_0 \\ \mathbf{w}_1 \\ \vdots \\ \mathbf{w}_p \end{bmatrix} \quad (2.26)$$

O cálculo segue o sentido *forward*, representado na figura 2.16, obedecendo o fluxo de informação dos neurônios da camada oculta no sentido de saída. O cálculo do sinal de entrada é realizado, segundo a equação (2.7) em seguida procede-se ao cálculo das ativações dos neurônios da camada oculta.

O cálculo das ativações dos neurônios da camada oculta é realizado segundo equação (2.8) e o estímulo segue como um sinal de entrada para a camada de saída. Neste processo adota-se, normalmente, a função ativação sigmóide ou tangente hiperbólica, conforme a equação (2.9).

As saídas desejadas são agrupadas como uma matriz  $\mathbf{Y}$  composta com  $n$  vetores linhas equivalentes ao número de amostras de treinamento.

$$\mathbf{Y} = \begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \\ \vdots \\ \mathbf{y}_n \end{bmatrix} \quad (2.27)$$

O problema passa a ser a determinação da matriz de pesos  $\mathbf{M}$  a partir da ativação da camada oculta  $\mathbf{Z}$  calculado para o conjunto das amostras de treinamento.

$$\mathbf{Y} = \mathbf{MZ} \quad (2.28)$$

A Matriz  $\mathbf{M}$  passa a ser determinada por mínimos quadrados resultando em (2.29), onde o termo  $\mathbf{Z}^\top (\mathbf{ZZ}^\top)^{-1}$  representa a matriz pseudoinversa de  $\mathbf{Z}$ .

$$\mathbf{M} = \mathbf{YZ}^\top (\mathbf{ZZ}^\top)^{-1} \quad (2.29)$$

## 2.5 O Algoritmo Least Squares Support Vector Regression

O LS-SVR é um algoritmo de regressão do tipo máquina de vetores-suporte ou *SVM* desenvolvido a partir da teoria do aprendizado estatístico elaborada por [Vapnik \(2000\)](#). O LS-SVR trata-se de um classificador supervisionado definido pela existência de um hiperplano ótimo de separação.

O problema dos classificadores *Support Vector Machines* (SVM) consiste em dividir classes distintas. As classes são divididas através da definição de um hiperplano que separa os  $n$  padrões em  $n$  regiões diferentes. A condição de existência desse hiperplano

é a de que os padrões são linearmente separáveis, entretanto na maioria dos casos essa não é atendida.

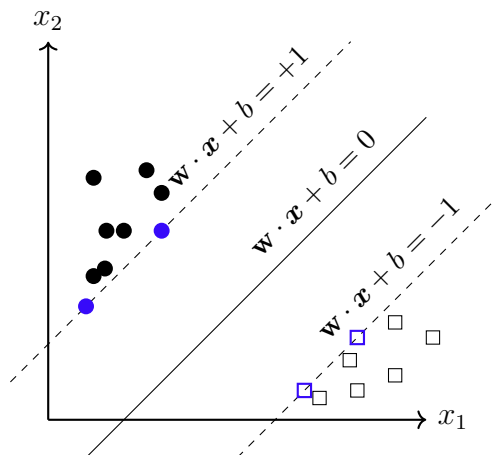
Seja  $\mathcal{X} \in \mathbb{R}^2$  um espaço de entrada com  $n$  vetores de treinamento representados por  $\mathcal{X} = \{\mathbf{x}_i, y_i\}_{i=1}^N$ , onde  $\mathbf{x}_i \in \mathbb{R}^2$  representa o vetor de entrada e  $y_i \in \{+1, -1\}$  o rótulo da classe associada ao  $i$ -ésimo exemplo. Supondo que o problema seja linearmente separável, portanto, atenda a condição de classificação, a representação da função linear que define o rótulo das classes é expressa como se segue.

$$y(\mathbf{x}_i) = \langle \mathbf{w}, \mathbf{x}_i \rangle + b \quad (2.30)$$

$$y(\mathbf{x}_i) = \begin{cases} -1, & \langle \mathbf{w}, \mathbf{x}_i \rangle + b < 0 \\ +1, & \langle \mathbf{w}, \mathbf{x}_i \rangle + b \geq 0 \end{cases} \quad (2.31)$$

onde  $\langle \mathbf{w}, \mathbf{x}_i \rangle$  representa o produto interno entre o vetor de pesos  $\mathbf{w}$  e o vetor de entrada  $\mathbf{x}_i$ , podendo também ser expresso na forma  $\langle \mathbf{w}, \mathbf{x}_i \rangle = \mathbf{w}^\top \mathbf{x}_i$ . A determinação do hiperplano estabelece uma margem de separação, definida pela distância entre os vetores suportes mais próximos a este. O Hiperplano que define a separação é obtido igualando a equação (2.30) a zero, porém a igualdade assume infinitas soluções nem todas ótimas.

Figura 2.18 – Vetores de Suporte em Classificação



Fonte: Autor.

Na figura 2.18 podemos observar que o hiperplano ótimo é equidistante entre os hiperplanos paralelos definidos pelos vetores de suporte das classes distintas (círculos e quadrados). Nota-se que todas as variáveis ficam do lado correto, isto define uma *margem rígida* de separação que define os rótulos dos vetores de entrada pela regra em (2.31).

Supondo que este mesmo problema é não-linearmente separável, portanto, a representação da função linear que define o rótulo das classes é expressa como abaixo:

$$y(\mathbf{x}_i) = \mathbf{w}^\top \varphi(\mathbf{x}_i) + b \quad (2.32)$$

$$\xi_i = y_i - y(\mathbf{x}_i) \quad (2.33)$$

onde  $\mathbf{w}^\top \varphi(\mathbf{x}_i)$  representa o produto interno, entre o vetor de pesos  $\mathbf{w}$  e a função de mapeamento não-linear  $\varphi(\mathbf{x}_i)$  que define a transformação do vetor de entrada no espaço de alta dimensão  $\mathbb{R}^2 \mapsto \mathbb{R}^n$ . A aplicação da função de mapeamento sobre o vetor de entradas é uma transformação expressa por  $\varphi : \mathcal{X} \mapsto \mathfrak{F}$ , onde  $\mathcal{X}$  é o espaço de entrada e  $\mathfrak{F}$  denomina-se espaço de características.

A transformação aplicada na variável  $\mathbf{x}$  por meio da função de mapeamento  $\varphi(\cdot)$  é uma operação que eleva a dimensão do vetor para um espaço, onde o problema é linearmente separável. Nestes casos, além da transformação não-linear, costuma-se consideraer uma variável de folga  $\xi_i$  na equação, permitindo pequenos erros.

No algoritmo LS-SVR todas as suposições são as mesmas até aqui, porém todos os dados são definidos como vetores suporte e o valor da função é determinada por meio de mínimos quadrados. A função discriminante  $y(\mathbf{x}_i)$  que determina o rótulo de classificação passa a representar a aproximação da variável de saída.

### 2.5.1 O Problema na forma primal

A determinação do hiperplano ótimo passa a ser uma função com restrições que, desenvolvida a partir da relação entre os vetores de suporte e o mesmo, é dada pela equação (2.34). Onde otimizar a margem significa minimizar a folga e a norma euclidiana da matriz de pesos.

$$\begin{aligned} \text{minimizar} \quad & \frac{1}{2} \|\mathbf{w}\|^2 + \gamma \sum_{i=1}^n \xi_i \\ \text{sujeito a} \quad & \begin{cases} y_i = \mathbf{w}^\top \varphi(\mathbf{x}_i) + b + \xi_i \\ |\xi_i| \geq 0 \end{cases} \end{aligned} \quad (2.34)$$

O problema definido desta maneira, nos permite aplicar o método dos *multiplicadores de Lagrange*, como solução do problema de otimização. A equação do lagrangeano em função das variáveis a se otimizar são dadas abaixo. Este problema definido com

as variáveis envolvidas na otimização, sejam elas a matriz de pesos  $\mathbf{w}$ , viés  $b$ , folga  $\boldsymbol{\xi}$  denomina-se como forma *primal*.

$$L(\mathbf{w}, b, \boldsymbol{\xi}, \boldsymbol{\alpha}, \boldsymbol{\beta}) = \frac{1}{2} \|\mathbf{w}\|^2 + \gamma \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i (\mathbf{w}^\top \varphi(\mathbf{x}_i) + b + \xi_i - y_i) - \sum_{i=1}^n \beta_i \xi_i \quad (2.35)$$

onde  $\alpha_i, \beta_i$  são os multiplicadores de lagrange da primeira e segunda restrição. Atendendo as condições para obtermos o ponto ótimo, temos as igualdades abaixo:

$$\begin{cases} \frac{\partial L}{\partial \mathbf{w}} = 0 & \rightarrow \mathbf{w} = \sum_{i=1}^n \alpha_i \varphi(\mathbf{x}_i), \\ \frac{\partial L}{\partial b} = 0 & \rightarrow \sum_{i=1}^n \alpha_i = 0, \\ \frac{\partial L}{\partial \xi_i} = 0 & \rightarrow \gamma = \alpha_i + \beta_i, \end{cases} \quad (2.36)$$

### 2.5.2 O Problema na forma dual

As relações obtidas em (2.36) substituídas em (2.35) definem a forma dual, onde as demais variáveis do problema são determinadas encontrando o ponto de sela do lagrangeano abaixo.

$$\begin{aligned} L(\boldsymbol{\alpha}, \boldsymbol{\beta}) &= \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j \varphi(\mathbf{x}_i)^\top \varphi(\mathbf{x}_j) + \sum_{i=1}^n (\alpha_i + \beta_i) \xi_i - \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j \varphi(\mathbf{x}_i)^\top \varphi(\mathbf{x}_j) \\ &\quad - b \sum_{i=1}^n \alpha_i - \sum_{i=1}^n \alpha_i \xi_i + \sum_{i=1}^n \alpha_i y_i - \sum_{i=1}^n \beta_i \xi_i \end{aligned} \quad (2.37)$$

Podemos eliminar o segundo, quinto e sétimo termo. O quarto termo desaparece sozinho pela relação em (2.36), podemos, também, somar o primeiro e terceiro termo, definindo o lagrangeano, apenas em função do multiplicador  $\boldsymbol{\alpha}$  restando apenas:

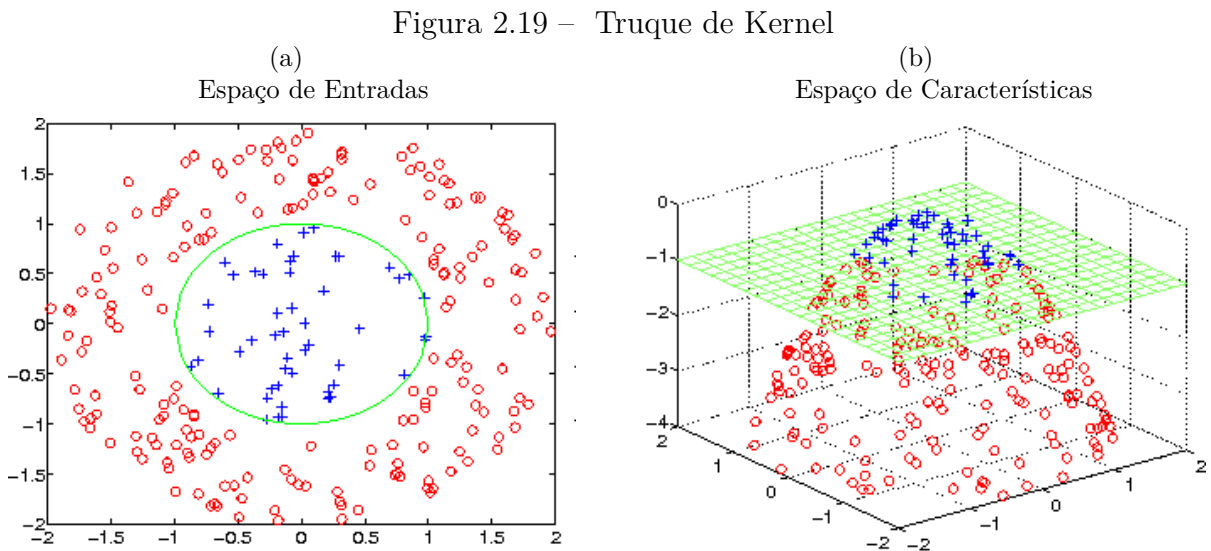
$$L(\boldsymbol{\alpha}) = \sum_{i=1}^n \alpha_i y_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \alpha_i \alpha_j \varphi(\mathbf{x}_i)^\top \varphi(\mathbf{x}_j) \quad (2.38)$$

Após estes passos o problema passa a ser a determinação do produto interno representado por:  $\varphi(\mathbf{x}_i)^\top \varphi(\mathbf{x}_j)$ , onde não se conhece a função de mapeamento nem, conseqüentemente, o resultado deste produto. A Solução deste problema é resolvido através de uma manipulação utilizando-se o *truque de Kernel*.

### 2.5.3 O Truque de Kernel

O truque de Kernel é definido como uma maneira de utilizar uma função pré-determinada, em vez de calcular o produto interno das funções de mapeamento não-linear, sendo equivalente a um mapeamento implícito. O Problema não-linearmente separável passa a ser separável num espaço de alta dimensão.

Uma forma concreta de compreender o processo de mapeamento do espaço de entradas no espaço de características  $\varphi : \mathcal{X} \mapsto \mathfrak{F}$ , é exemplificado pela figura 2.19. O hiperplano separa linearmente o espaço de características  $\mathfrak{F} \in \mathbb{R}^3$ , representado em 2.19b, sendo equivalente a uma secção circular no espaço de entrada  $\mathcal{X} \in \mathbb{R}^2$ , representado em 2.19a, onde todos os dados são separados corretamente por um hiperplano.



Fonte: Adaptado de (WU *et al.*, 2005).

Burges (1998) realiza a demonstração do teorema para que o produto interno possa ser representado pela função kernel, comprovando que existem funções  $\varphi(\mathbf{x}_i)$ ,  $\varphi(\mathbf{x}_j)$  tal que atendam a seguinte condição:

$$K(\mathbf{x}_i, \mathbf{x}_j) = \langle \varphi(\mathbf{x}_i) \varphi(\mathbf{x}_j) \rangle = \varphi(\mathbf{x}_i)^\top \varphi(\mathbf{x}_j) \quad (2.39)$$

O produto interno da função de mapeamento não precisa ser computado, portanto, podendo ser representado por diversas funções kernel, sendo usuais a linear, polinomial e RBF, sendo obtidos como na tabela 2.4.

Tabela 2.4 – Principais funções *Kernel*

<i>Kernel</i>	Descrição
Linear	$k(\mathbf{x}, \mathbf{x}_i) = \mathbf{x}_i^\top \mathbf{x}$
Polinomial	$k(\mathbf{x}, \mathbf{x}_i) = (\mathbf{x}_i^\top \mathbf{x} + 1)^d$
Sigmoidal	$k(\mathbf{x}, \mathbf{x}_i) = \exp(-\ \mathbf{x} - \mathbf{x}_i\ ^2 / \sigma^2)$

Fonte: Adaptado de (ROCHA NETO, 2017).

Após atender todas as condições e ser determinada a função kernel, o sistema pode ser rearranjado na forma de equação linear,  $\mathbf{A}\mathbf{X} = \mathbf{B}$ , onde a solução dos multiplicadores e vieses é representada na forma:

$$\mathbf{A} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix}; \quad \mathbf{A} = \left[ \begin{array}{c|c} 0 & \mathbf{1}^\top \\ \hline \mathbf{1}^\top & \boldsymbol{\Omega} + \gamma^{-1}I \end{array} \right] \text{ e, então, a solução é dada por: } \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \mathbf{A}^{-1} \begin{bmatrix} 0 \\ \mathbf{y} \end{bmatrix};$$

onde  $\boldsymbol{\Omega} \in \mathbb{R}^{n \times n}$ , os elementos da matriz são dados por  $\Omega_{ij} = K(\mathbf{x}_i, \mathbf{x}_j) = \varphi(\mathbf{x}_i)^\top \varphi(\mathbf{x}_j)$ ;  $\mathbf{1} = [1, 1, \dots, 1]^\top$ ;  $\mathbf{y} = [y_1, y_2, \dots, y_n]^\top$ .

A Solução dos valores preditos é, finalmente, determinada com os valores dos multiplicadores ótimos  $\boldsymbol{\alpha}$  e o viés  $b$ , por meio das relações (2.36) e (2.39) resultando em:

$$y(x_i) = \sum_{i=1}^n \alpha_i K(\mathbf{x}, \mathbf{x}_i) + b \quad (2.40)$$

Uma das vantagens, resumidamente, do algoritmo LS-SVR e demonstrada na literatura, está no fato de a solução ótima ser obtida pelo MMQO. Smola e Schölkopf (2004) cita os autores Goldstein (1980), McCormick (1983), Mangasarian (1969), Vanderbei (1997) que realizaram demonstração que o lagrangeano na forma primal e dual tem pontos de sela e que são pontos ótimos para as duas formas.



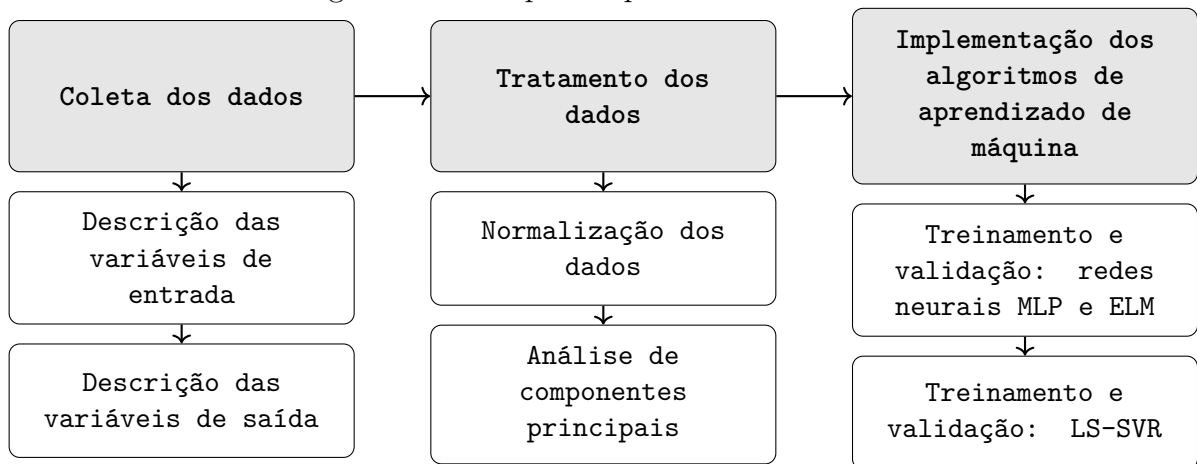
### 3 METODOLOGIA

Neste capítulo realizou-se uma apresentação do procedimento adotado da coleta de dados até a implementação dos algoritmos. A coleta dos dados foi detalhada juntamente com as considerações realizadas na seção 3.1. Na seção 3.2 é descrito o processo de tratamento aplicado sobre o banco de dados. Na seção 3.2.1 e 3.2.2 são estabelecidas, respectivamente, uma descrição dos métodos de normalização e análise de componentes principais como empregados na modelagem.

Na seção 3.3 é descrita a proposta de utilização dos dados adotados nos métodos de aprendizado de máquina implementados no Octave. Na seção 3.3.1 e 3.3.2 é descrito o procedimento de determinação de treinamento e validação aplicado, respectivamente, a rede neural ELM, MLP e LS-SVR.

O procedimento adotado se divide em três etapas esquematizadas na figura 3.1. A primeira exige a especificação das variáveis e se inicia por meio da coleta de dados. A segunda é o tratamento dos dados e funciona como uma pré-análise. A etapa final é a implementação em cada um dos algoritmos de aprendizado de máquina no programa utilizado.

Figura 3.1 – Etapas do procedimento adotado



Fonte: Autor.

#### 3.1 Coleta dos Dados

Os ensaios triaxiais correspondem por 197 observações de 61 ensaios triaxiais, sendo conseqüente por mais de uma determinação para cada nível de deformação axial

específica. Os ensaios triaxiais coletados são provenientes, principalmente, de trabalhos de mestrado e doutorado dos autores citados nos anexos A e B, sendo realizada por estes uma descrição detalhada das variáveis envolvidas. O banco de dados utilizado neste trabalho é oriundo de 46 ensaios triaxiais do tipo *Consolidated Drained* (CD) e 15 do tipo de *Consolidated Undrained* (CU) da literatura. Todos os parâmetros geotécnicos foram coletados em termos de tensões efetivas.

Nos estudos que compõem a base de dados os únicos integralmente descritos são os relativos e os destinados aos ensaios triaxiais, portanto ainda que existam informações relativas ao aterro, estas não foram utilizadas. Os ensaios triaxiais que compõem a amostra foram realizados em células de dimensões padrões e de grandes proporções.

A composição gravimétrica e o tempo de decomposição são referentes ao material coletado em grande quantidade de aterros, sendo, posteriormente, divididos e destinados em porções menores ao preparo e molde dos corpos de prova. Os índices físicos são alusivos aos corpos de provas dos ensaios triaxiais. As observações de ângulo de atrito e intercepto coesivo efetivos são relativos aos corpos de prova ensaiados em diferentes níveis de tensões confinantes efetivas e deformação axial específica.

Na maioria dos trabalhos cada autor realizou pelo menos um ensaio triaxial e múltiplas determinações de intercepto coesivo e ângulo de atrito efetivos (tabela 3.1). Nos trabalhos de Babu *et al.* (2012), Caicedo *et al.* (2002) e Reddy *et al.* (2009a, 2009b, 2011, 2015) as únicas observações determinadas visaram a avaliar a envoltória de Mohr-Coulomb sobre o critério de deformação designado. Carvalho (1999) teve como objeto de estudo da variedade de triaxiais efetuados, as diversas condições de ensaio e peso específico dos resíduos. Os diversos ensaios realizados por Gomes (2008) dispôs sobre resíduos de diferentes horizontes de coleta do aterro estudado. No ensaio de Grisolia *et al.* (1995b) o único triaxial realizado teve como fim de análise uma vasta amplitude de critério de deformação. Nos trabalhos de Haque (2007) e Hossain e Haque (2009) o objeto de estudo dos diferentes ensaios triaxiais foram as distintas composições determinadas pela variação de material de cobertura. Nos triaxiais efetivados por Shariatmadari *et al.* (2013, 2015) foram avaliados resíduos de diferente idades de um mesmo aterro. Nos ensaios executados por Machado *et al.* (2005) e Nascimento (2007) os diversos triaxiais foram realizados na amostra de resíduos originários de um mesmo aterro, porém com diferentes composições e tempo de decomposição. Nos triaxiais realizados por Chen *et al.* (2017), Zhan *et al.* (2008)

e Rong *et al.* (2011) para uma amostra de resíduos foram avaliados até dois critérios de deformação para as amostras dos aterros examinados.

Tabela 3.1 – Resumo da coleta de ensaios triaxiais por autor

Autor(es)	Condição de ensaio	Total de triaxiais	Total de pares $c'$ e $\phi'$
Babu <i>et al.</i> (2012)	CD	1	1
Caicedo <i>et al.</i> (2002)	CU	1	1
Carvalho (1999)	CD	15	73
Carvalho (1999)	CU	4	12
Chen <i>et al.</i> (2017)	CD	2	4
Gomes (2008)	CD	6	40
Grisolia <i>et al.</i> (1995b)	CD	1	7
Haque (2007) e Hossain e Haque (2009)	CD	12	12
Machado <i>et al.</i> (2005)	CD	2	10
Nascimento (2007)	CD	4	16
Nascimento (2007)	CU	2	8
Reddy <i>et al.</i> (2009a)	CU	1	1
Reddy <i>et al.</i> (2009b)	CU	1	1
Reddy <i>et al.</i> (2011)	CU	1	1
Reddy <i>et al.</i> (2015)	CU	1	1
Shariatmadari <i>et al.</i> (2013, 2015)	CU	4	4
Zhan <i>et al.</i> (2008) e Rong <i>et al.</i> (2011)	CD	3	5

Fonte: Autor.

### 3.1.1 *Descrição das variáveis de entrada*

As variáveis coletadas dos trabalhos, anexo A, são resultantes de ensaios empregados com métodos e abrangência distintas. Na descrição de cada pesquisador observam-se diferenças determinantes da metodologia de ensaio aplicada que se referem ao objeto de estudo dos trabalhos.

Na determinação da composição gravimétrica observaram-se diferenças alusivas à classificação dos diversos materiais constituintes e, também, dos estados de alteração dos resíduos. A fração pastosa, que corresponde ao material orgânico agregado ao granular, é determinada, segundo a norma MODECOM da ADEME ou através de critérios dos autores, conjuntamente com a norma D2974-13 ASTM (2013). A adoção do sistema de classificação de Grisolia *et al.* (1995a) fez-se necessário como forma de compatibilizar a composição gravimétrica.

Nos ensaios de composição foram definidos os constituintes do RSU em função da porcentagem em massa. Nas amostras de Babu *et al.* (2012), Carvalho (1999), Gomes (2008), Reddy *et al.* (2009a, 2009b, 2011, 2015), Shariatmadari *et al.* (2013, 2015), Haque (2007) e Hossain e Haque (2009) Machado *et al.* (2005), Nascimento (2007) os resíduos foram divididos pelo tipo identificável e pela fração pastosa, sendo indicados nesta fração os sólidos voláteis presentes. Nos estudos de Caicedo *et al.* (2002), Chen *et al.* (2017) e Zhan *et al.* (2008) e Rong *et al.* (2011) os materiais foram agrupados em graus de semelhança. Nas amostras de Grisolia *et al.* (1995b) os resíduos são identificados pelo tipo e a fração orgânica indicadas diretamente.

Na determinação do tempo de decomposição os autores realizaram estimativas, revisão da data de deposição ou condicionaram ao tempo decorrido à execução do ensaio. Reddy *et al.* (2009a, 2009b, 2011, 2015), Babu *et al.* (2012), Haque (2007) e Hossain e Haque (2009) ensaiaram amostras de resíduos frescos retirados de leiras ou estações de transferências, sendo decorrido um período indicado de semanas ou meses até seu ensaio. Chen *et al.* (2017), Shariatmadari *et al.* (2013, 2015), Machado *et al.* (2005) e Nascimento (2007) ensaiaram resíduos frescos e antigos que tiveram sua idade determinada pelos autores. Carvalho (1999), Zhan *et al.* (2008) e Rong *et al.* (2011) ensaiaram resíduos antigos que tiveram sua idade estimada. Grisolia *et al.* (1995b) efetuou triaxiais, apenas, em resíduos frescos. Gomes (2008) realizou uma estimativa e uma determinação do tempo de decomposição pela data das amostras, levando em consideração o início, fim da deposição

e o recolhimento dos resíduos coletados.

Na determinação da umidade e peso específico os autores buscaram representar condições de campo estipuladas e presentes que foram determinadas através de ensaios de campo e laboratório dos aterros estudados. Nos trabalhos de [Carvalho \(1999\)](#) e [Nascimento \(2007\)](#) buscou-se representar condições estabelecidas de peso específico e de umidade natural e saturada assinaladas. Nos estudos de [Reddy \*et al.\* \(2009a, 2009b, 2011, 2015\)](#), [Grisolia \*et al.\* \(1995b\)](#), [Shariatmadari \*et al.\* \(2013, 2015\)](#) e [Haque \(2007\)](#) e [Hossain e Haque \(2009\)](#) foi designada uma estreita faixa de valores para o peso específico e um valor desejado para a umidade. Nos triaxiais executados por [Chen \*et al.\* \(2017\)](#), [Caicedo \*et al.\* \(2002\)](#), [Babu \*et al.\* \(2012\)](#), [Zhan \*et al.\* \(2008\)](#) e [Rong \*et al.\* \(2011\)](#) foi indicado o valor alvo que representam a umidade e peso específico.

Os níveis de deformação e tensão de confinamento são dados de entrada que caracterizam mecanicamente os RSU, sendo indicados, para todos os trabalhos, cada um dos valores para cada determinação de intercepto coesivo e ângulo de atrito efetivos obtidos de cada ensaio triaxial realizado.

Na determinação da tensão de confinamento efetiva máxima nos estudos dos autores, os níveis empregados de tensões confinante foram indicados para cada ensaio. Nos triaxiais do tipo CD de [Babu \*et al.\* \(2012\)](#), [Carvalho \(1999\)](#), [Chen \*et al.\* \(2017\)](#), [Gomes \(2008\)](#), [Grisolia \*et al.\* \(1995b\)](#), [Haque \(2007\)](#) e [Hossain e Haque \(2009\)](#), [Machado \*et al.\* \(2005\)](#), [Nascimento \(2007\)](#) e [Zhan \*et al.\* \(2008\)](#) e [Rong \*et al.\* \(2011\)](#) a tensão de confinamento pela condição de drenagem é dada em termo efetivo. Nos triaxiais do tipo CU de [Caicedo \*et al.\* \(2002\)](#), [Reddy \*et al.\* \(2009a, 2009b, 2011, 2015\)](#), [Babu \*et al.\* \(2012\)](#), [Haque \(2007\)](#) e [Shariatmadari \*et al.\* \(2013, 2015\)](#), embora as condições de drenagem não sejam as mesmas dos ensaios CD, as tensões são informadas em termos efetivos. Nos ensaios triaxiais do tipo CU realizados por [Carvalho \(1999\)](#) e [Nascimento \(2007\)](#) a tensão de confinamento não é definida como efetiva, porém seu valor é obtido analiticamente pelas equações das trajetórias de tensão informadas. As tensões de confinamento máxima efetivas foram adotadas como forma de representar o maior nível de tensão ao qual os triaxiais foram executados.

As variáveis de entrada coletadas são definidas nos termos descritos nos ensaios, sendo relativas as amostras de aterro de grande proporções destinadas a moldagem dos corpos de prova ou não reservadas aos triaxiais, porém tratadas como representativas

dos resíduos ensaiados e das condições existente nos aterros. Os dados coletados são, portanto, variáveis físicas e mecânicas relativas aos corpos de prova dos resíduos. As variáveis coletadas que compõem os dados de entradas são as seguintes:

- **Composição gravimétrica (Classes A; B e C, %):** foi expressa através do sistema de classificação de [Grisolia \*et al.\* \(1995a\)](#). A composição refere-se as amostras coletadas em grandes quantidades para moldar os corpos de prova.
- **Tempo de decomposição (t, anos):** nos casos de resíduos sintéticos e frescos é definido como o tempo decorrido até a execução do ensaio triaxial. Nos casos em que os resíduos ensaiados são amostras recolhidos diretamente dos aterros sanitários é a estimativa ou valor indicado nos trabalhos.
- **Umidade em base seca ( $\omega$ , %):** é relativo ao valor determinado para os corpos de prova. No geral foi definido um valor alvo desejado que representem as condições de campo ou ao qual deseja-se analisar os RSU.
- **Peso específico seco ( $\gamma_d$ , KN/m<sup>3</sup>):** assim como a umidade é relativo ao valor determinado para os corpos de prova. No geral, também, se define um valor alvo, tal qual a umidade, no entanto, nos diversos estudos foram determinados os pesos específicos para cada corpo de prova ou a faixa de valores obtidos no remolde.
- **Tensão de confinamento efetiva máxima ( $\sigma'_c$ , kPa):** nos ensaios triaxiais descritos a envoltória de Mohr-Coulomb foi obtida a partir de pelo menos três valores de tensões de confinamento e desviadora diferentes. A tensão de confinamento efetiva máxima associa os parâmetros da envoltória de Mohr-Coulomb ao nível de máximo tensão ao qual os parâmetros são válidos.
- **Deformação axial Específica ( $\varepsilon_a$ , %):** por não ocorrer ruptura física nos ensaios triaxiais de RSU a deformação axial específica torna-se uma importante variável de referência associando-se aos parâmetros da envoltória. Nos estudos observou-se uma faixa de valores para a deformação axial específica dentre 1% e 45% . A utilização de uma extensa faixa de valores, pelos autores, é devido à avaliação da mobilização dos parâmetros da envoltória de Mohr-Coulomb.

### 3.1.2 Descrição das variáveis de saída

As variáveis de saída utilizadas descrevem o comportamento de resistência ao cisalhamento. Elas são os parâmetros geotécnicos da envoltória de Mohr-Coulomb. As variáveis coletadas escolhidas que compõem as saídas são as seguintes:

- Intercepto coesivo efetivo ( $c'$ )
- Ângulo de atrito efetivo ( $\phi'$ ).

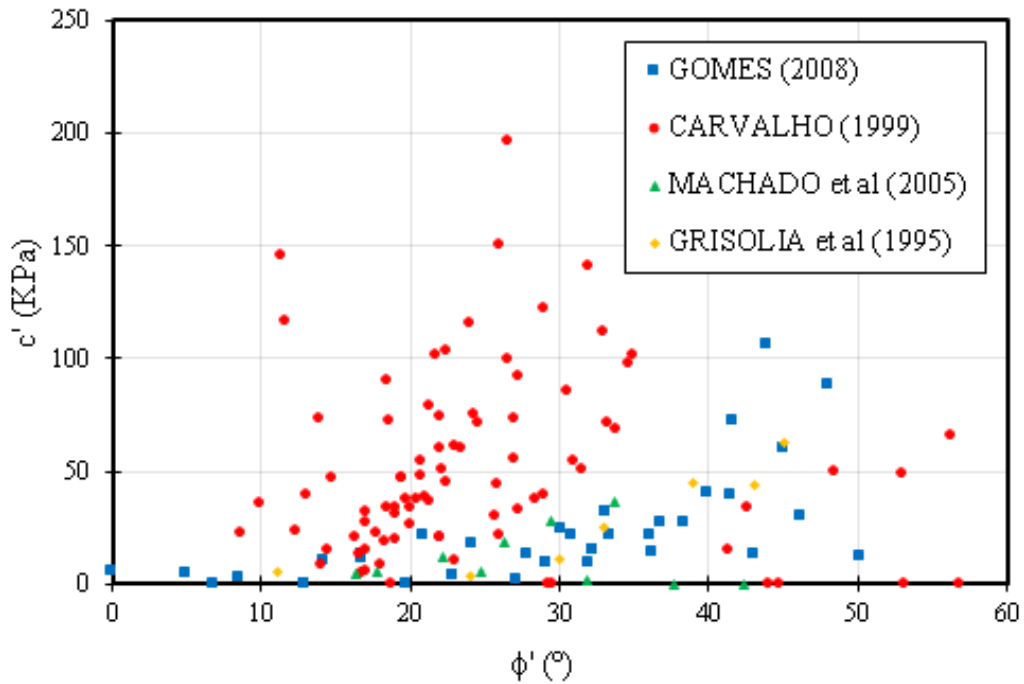
Os parâmetros de Mohr-Coulomb foram obtidos para os corpos de prova pelos ensaios triaxiais dos trabalhos pesquisados. O intercepto coesivo e ângulo de atrito efetivos foram coletados associados aos diferentes níveis de deformação axial específica e de tensão confinante efetiva máxima aplicadas ensaiados.

A utilização de diferentes níveis de deformação axial visaram a avaliação da mobilização dos parâmetros da envoltória, sendo obtidas diversas observações para um mesmo ensaio triaxial. A magnitude das tensões confinante máximas descritas é resultado direto das diferenças dos equipamentos triaxiais usuais e de grande escala utilizados. Os diferentes níveis de tensões delimitam a validade dos parâmetros de resistência ao cisalhamento.

Na representação do intercepto coesivo e ângulo de atrito efetivos foram observados níveis de deformação entre 1 e 40% e níveis de tensão confinante máxima entre 18,2 e 400kPa, anexo B. Nos triaxiais de [Carvalho \(1999\)](#), [Gomes \(2008\)](#), [Grisolia \*et al.\* \(1995b\)](#), [Machado \*et al.\* \(2005\)](#) e [Nascimento \(2007\)](#) foram avaliados a mobilização dos parâmetros para uma extensa faixa de níveis de deformação e altos níveis de tensão. Nos triaxiais de [Babu \*et al.\* \(2012\)](#), [Caicedo \*et al.\* \(2002\)](#), [Haque \(2007\)](#) e [Hossain e Haque \(2009\)](#), [Shariatmadari \*et al.\* \(2013, 2015\)](#) e [Caicedo \*et al.\* \(2002\)](#), [Reddy \*et al.\* \(2009a, 2009b, 2011, 2015\)](#) foram executadas uma única determinação sobre o critério de deformação, ao qual consideraram os parâmetros muito ou totalmente mobilizados. [Chen \*et al.\* \(2017\)](#) e [Zhan \*et al.\* \(2008\)](#) e [Rong \*et al.\* \(2011\)](#) realizaram duas determinações para os critérios de deformação de 10 e 20% sob uma tensão confinante de 400kPa.

Os resultados obtidos permitiram avaliar os critério de deformação variados e a tendência de mobilização dos parâmetros. Nos triaxiais coletados representados por [Carvalho \(1999\)](#), [Gomes \(2008\)](#) e [Grisolia \*et al.\* \(1995b\)](#) (figura 3.2) observou-se que há uma grande dispersão. Nos ensaios não é possível identificar uma tendência bem definida capaz de agrupar as envoltórias de Mohr-Coulomb dos RSU.

Figura 3.2 – Representação das saídas coletadas:  $c'$ (kPa) x  $\phi'$ ( $^{\circ}$ )



Fonte: Autor

### 3.2 Tratamento dos dados

Antes da execução da modelagem é necessária a realização do tratamento dos dados. No tratamento realizou-se a normalização dos dados, visando acelerar a execução dos algoritmos e, após isto, utilizou-se da ferramenta de análise de componentes principais que consiste em um importante instrumento de análise e adequação dos dados.

O tratamento dos dados no estudo do aprendizado de máquina é uma etapa opcional e pode ter seu escopo definido de acordo com os métodos utilizados. No presente estudo fez-se uso da análise de componentes principais e normalização visando aperfeiçoar as estimativas dos modelos e a prevenção ao *overfitting* nas redes neurais.

#### 3.2.1 Normalização dos dados de entrada

A normalização dos dados é um procedimento empregado com o intuito de estabelecer uma mesma escala para as variáveis de entrada e saída. A normalização facilita o processo de treinamento, sendo definido dentro do intervalo de 0 e 1 (equação 3.1) e -1 e 1 (equação 3.2). A normalização é determinada definindo os valores máximos e mínimos das variáveis empregadas.



$$X_{norm} = \frac{X - X_{m\acute{a}x}}{X_{m\acute{a}x} - X_{m\acute{i}n}} \quad (3.1)$$

$$X_{norm} = 2 \left( \frac{X - X_{m\acute{a}x}}{X_{m\acute{a}x} - X_{m\acute{i}n}} \right) - 1 \quad (3.2)$$

A normalização dos dados aplicada sobre o problema redefine o intervalo sem alterar a relação original entre valores. Os valores máximos e mínimos servem como referência do modelo para normalização. A estatística descritiva de média, mediana e desvio padrão auxiliam na análise de dispersão dos dados e identificação de possíveis pontos ruidosos.

Tabela 3.2 – Estatística descritiva dos dados de entrada dos RSU

Variável/Medida		Máximo	Mínimo	Média	Mediana	Desvio Padrão
Composição Gravimétrica (Classes)	A (%)	95,5	7,5	50,7	61,0	18,9
	B (%)	71,1	0,0	32,5	23,5	18,0
	C (%)	48,2	4,5	16,1	16,0	7,3
T (anos)		21,0	0,0	8,3	6,0	6,4
$\omega$ (%)		222	20	64	54	35
$\gamma_d$ (KN/m <sup>3</sup> )		13,7	3,4	8,5	8,8	2,7
$\varepsilon_a$ (%)		40	1	20	20	10
$\sigma'_3$ máxima (kPa)		400,0	18,2	265,9	207,0	124,5
$c'$ (kPa)		196,0	0,0	32,2	21,6	33,5
$\phi'$ (°)		66,0	0,0	26,6	24,9	11,3

Fonte: Autor.

### 3.2.2 Análise de Componentes Principais

A análise de componentes principais é um método que visa transformar um conjunto de dados em outro de igual ou menor dimensão, visando a otimização da implementação das técnicas de aprendizado de máquina e das informações contidas nas variáveis. O procedimento elimina o efeito da correlação existente dos dados e determina, através da transformação matricial aplicada, os componentes principais.

O método faz uso da matriz de covariância  $C_x$  e seus autovalores e autovetores. O processo pode ser aplicado em quatro etapas até a determinação dos componentes principais. Na primeira etapa obtemos a matriz de covariância que é compreendida como a medida de dispersão entre variáveis, denotando uma relação de interdependência. Os elementos da matriz de covariância são definidos estatisticamente pela equação (3.3), sendo a média do somatório do produto entre a diferença das variáveis  $x_i$  e  $x_j$  e suas respectivas médias  $\bar{x}_i$  e  $\bar{x}_j$ .

$$\sigma_{ij} = \frac{\sum_{i=1}^N (x_i - \bar{x}_i)(x_j - \bar{x}_j)}{N - 1} \quad (3.3)$$

Na segunda etapa, temos a determinação dos autovalores  $\lambda$  e autovetores  $V$  da matriz  $C_x$  e a matriz de covariância dos componentes principais. Os autovalores podem ser obtidos através de processo direto, ou através da matriz de covariância transformada  $C_y$ , onde os pares distintos de variáveis,  $\sigma_{ij} = 0$  quando  $i \neq j$ . A matriz diagonal  $C_y$  que, consiste somente nas variâncias (equação 3.4) é obtida após determinação dos autovetores  $V$  e seus elementos são equivalente aos autovalores  $\lambda$  ordenados em sua diagonal principal.

$$C_y = V^T C_x V \quad (3.4)$$

Na terceira etapa temos a definição da tolerância desejada ao conjunto de dados transformados. A tolerância dos dados é definida como o limite para a razão do somatório acumulado da variância dos elementos da matriz  $C_y$  pelo somatório de todos os elementos. A matriz de autovetores e autovalores são ordenados de maneira correspondente e decrescente.

Na quarta etapa é realizada a transformação dos dados originais para os componentes principais, que são os vetores resultantes de todo o processo. A direção dos componentes principais é determinada pela matriz dos autovetores. Os componentes principais se dá pela multiplicação da matriz de autovetores  $V$  pelos dados de entrada  $X$ , sendo estes os dados de entrada transformados.

$$Y = V^T X \quad (3.5)$$

Neste trabalho, aplicou-se a análise de componentes principais para utilização de uma base de dados reduzida, visando diminuir o tempo de processamento e a quantidade de parâmetros ajustáveis que os modelos demandam.

A análise de componentes principais tem papel fundamental na redução da dimensão dos dados e, conseqüentemente, na redução do número total de pesos, sendo utilizada esta redução como garantia de obediência a regra empírica (3.6). A redução da dimensão dos dados vem acompanhada da transformação linear dos dados originais, desta forma os dados de entrada inseridos no problema são os dados transformados e reduzidos aos seus componentes principais.

A redução da dimensão dos dados é realizada examinando-se a tolerância definida e o acumulado percentual da variância explicada. Os componentes principais são os vetores que possuem a maior variância através do qual define-se o conjunto de dados. Os autovetores da matriz de covariância formam a matriz de transformação linear dos dados de entrada.

A análise dos componentes principais das observações de entrada (tabela 3.3) forneceu a verificação da existência de uma grande concentração da variância no primeiro componente, representado mais da metade do total. O conjunto definido pelos 5 primeiros componentes principais correspondem por 93,62% e somado ao sexto e sétimo são equivalentes à 99,95% da variância dos dados.

Tabela 3.3 – Variância dos componentes principais: nominal, explicada e explicada acumulada

Variável/Medida	Variância	Variância Explicada (%)	Variância Explicada Acumulada (%)
Componente Principal	1	0,2561	52,73%
	2	0,0767	15,79%
	3	0,0528	10,88%
	4	0,0444	9,14%
	5	0,0246	5,08%
	6	0,0213	4,38%
	7	0,0095	1,95%
	8	0,0002	0,05%

Fonte: Autor.

No trabalho, afim de obter o melhor equilíbrio entre pesos acrescentados e tolerância definida pela variância explicada, utilizou-se dos 5 primeiros componentes principais na base dos dados. Os dados de entrada são transformados multiplicando os 5 autovetores correspondentes ao 5 componentes principais de maior variância.

### 3.3 Implementação dos algoritmos de aprendizado de máquina

Os algoritmos foram implementados na linguagem do *GNU Octave*, sendo definidos a rede e parâmetros através de funções e métodos auxiliares necessários para a realização de estimativas. No procedimento adotado foram empregados uma divisão de amostras de treino e validação para as redes neurais e o LS-SVR.

#### 3.3.1 Treinamento e validação: Redes Neurais

A capacidade da rede neural de se ajustar aos dados que se desejam estimar exige a avaliação de uma amostra de treinamento e outra de validação. O processo de treinamento consiste no ajuste dos parâmetros das redes neurais e a validação em estimar a cada ajuste a convergência do *Mean Square Error* (MSE) para a amostra de validação.

A avaliação da arquitetura das redes neurais foi feita através do procedimento de *grid-search* que consiste na avaliação do treinamento de um sucessivo número de neurônios por vez. O procedimento deve restringir ainda um valor máximo, também, com o intuito de limitar o número de parâmetros ajustáveis e reduzir a possibilidade de ocorrência do *overfitting*.

Na limitação do número de parâmetros, adotou-se o procedimento heurístico de Baum-Haussler (equação 3.6). A heurística indica serem necessários uma quantidade  $N$  total de dados maior do que a razão entre o número de parâmetros ajustáveis totais  $Z$  e o erro tolerado  $\varepsilon$  estabelecido. No estudo considerou-se um erro tolerado de 15%, o que representam 29,5 parâmetros para as redes neurais.

$$N > \frac{Z}{\varepsilon} \quad (3.6)$$

A determinação das redes neurais ELM e MLP com menor quantidade de neurônios e melhor performance visa estabelecer uma arquitetura capaz de estimar ade-

quadamente as saídas. No procedimento proposto foi adotado uma rede neural por saída, visando reduzir o número de pesos e agilizar o processo de treinamento.

A distinção no treinamento entre as redes neurais, no entanto, está no processo de ajuste dos pesos. Na rede neural ELM o treinamento é instantâneo e na rede neural MLP é iterativo, sendo calculado por meio de *epochs* que consiste em todo um ciclo de cálculo e ajuste dos pesos. O procedimento adotado aos dois algoritmos de redes neurais MLP com 1 camada oculta e ELM, em síntese, para o conjunto de dados é dado abaixo.

- Carregamento dos Dados
- Divisão dos dados em treinamento (80%) e validação (20%)
- *Grid Search* pelo número de neurônios
- Avaliação dos resultados dos coeficientes de determinação ( $R^2$ ) e MSE

### ***3.3.2 Treinamento e validação: Least-Square Support Vector Regression***

O treinamento no LS-SVR é necessário para determinação do parâmetro de regularização  $\gamma$  e o parâmetro da função kernel gaussiana adotada  $\sigma$ . A amostra de teste é utilizada para validar os valores obtidos para os parâmetros. O treinamento foi realizado utilizando o método *global random search* que consiste no teste de  $n$  valores dentro de um intervalo pré-determinado, caso o valor do parâmetro da iteração reduza a função custo, então este é guardado para comparação com a iteração seguinte e assim repetindo-se sucessivamente.

No algoritmo LS-SVR o procedimento realizado difere no processo de busca dos hiperparâmetros do algoritmo. Aplicou-se o processo abaixo ao conjunto de dados.

- Carregamento dos Dados
- Divisão dos dados em treinamento (80%) e validação (20%)
- *Global Random Search* pelos hiperparâmetros  $\gamma$  e  $\sigma$
- Avaliação dos resultados dos coeficientes de determinação ( $R^2$ ) e MSE

## 4 APRESENTAÇÃO DOS RESULTADOS

Neste capítulo, apresentam-se os resultados da metodologia estabelecida para a execução do trabalho. O presente estudo se divide em duas etapas, sendo a primeira relativa à utilização da metodologia adotada e a segunda uma demonstração prática, através da representação de um estudo de caso.

Na seção 4.1 apresentam-se os resultados obtidos das redes neurais ELM e MLP treinadas. A utilização das redes neurais treinadas visa a estimativa de valores para a amostra fora do conjunto de dados utilizados no treinamento. O algoritmo LS-SVR foi empregado, principalmente, para avaliação da estimativa dos valores para o conjunto de dados, considerando a propriedade do algoritmo de convergir para a solução ótima, através da resolução do lagrangeano.

Na seção 4.2 apresenta-se o estudo de caso do aterro Santo Tirso, estudado e descrito por [Gomes \(2008\)](#). Os dados coletados para o aterro descrito são utilizados para predição da envoltória de Mohr-Coulomb e, ao final, estabelecida uma análise de estabilidade de talude, considerando dois cenários representados, utilizando o programa *Slide 6.0* da *Rocscience*.

### 4.1 Implementação dos algoritmos de aprendizado de máquina

A implementação dos algoritmos através do código segue a rotina demonstrada na seção 3.3. Nas redes neurais o procedimento seguido é basicamente o mesmo e no LS-SVR há uma ligeira diferença quanto à determinação dos parâmetros de regularização e a constante do Kernel que são as variáveis do modelo definidas pelo processo de *global random search*. Os códigos foram executados utilizando o *GNU Octave* e sua linguagem de scripts conforme apêndice A,B e C .

#### 4.1.1 *Treinamento e Validação: Redes Neurais*

Nas redes neurais MLP o treinamento foi acelerado por meio do algoritmo de Levenberg-Marquardt. No processo de treinamento definiu-se um critério de parada de gradiente mínimo do erro e do número máximo de *epochs*. No último caso quando ocorrida a convergência considera-se que o problema encontra-se preso a um ponto de sela e as iterações posteriores elevam o custo computacional sem acrescentar melhores resultados.

Nas redes neurais ELM utiliza-se o processo de treinamento sem necessidade de critérios de paradas pela realização instântanea do cálculo. O Resultado encontrado é o resultado ótimo obtido pela capacidade de ajuste da rede para as amostras do conjunto definidas aleatoriamente.

A curva de aprendizagem de estimação decresce monotonamente para um número crescente de épocas, da maneira usual. Diferentemente, a curva de aprendizagem de validação decresce monotonamente para um mínimo e, então começa a crescer conforme o treinamento continua (HAYKIN, 2008).

As redes neurais foram consideradas válidas, quando o *Mean Square Error* converge a uma mesma magnitude para as amostras de validação e treino. O valor do coeficiente de determinação, juntamente com o *MSE* serve como avaliação da qualidade do ajuste dos resultados preditos ao valores reais.

#### 4.1.2 *Redes Neurais Multilayer-Perceptron*

No procedimento de modelagem do intercepto coesivo e ângulo de atritos efetivos são utilizadas uma rede neural MLP para cada uma destas variáveis visando um melhor ajuste para os resultados preditos. A determinação da arquitetura da rede neural MLP é o cerne do problema que tem como variante apenas o número de neurônios da única camada oculta adotada. O número de neurônios foi avaliado pelo *grid-search* dentro do limite máximo de 4 neurônios.

O procedimento de *Grid-search* (tabela 4.1) nos revelou o ganho de desempenho das redes neurais MLP para as amostras no geral. O resultado do MSE entre as amostras de treino e validação não difere em mais de 29% para ambos  $c'$  e  $\phi'$ , sendo ainda menor a diferença quando comparado com um número maior de neurônios. O  $R^2$  demonstra a mesma similaridade entre amostras de treino e validação das duas saídas, sendo observada uma diferença máxima de 18% entre elas. O tempo de execução observado variou entre 4 a 14 segundos até o critério de parada de número de *epochs* ser atendido. O desempenho das redes neurais MLP para as saídas melhora com o acréscimo de neurônios, porém o número de parâmetros ajustáveis cresce mais rapidamente, sendo adicionados 7 parâmetros a cada neurônio acrescentado na camada oculta.


Tabela 4.1 – *Grid-search* rede neural MLP: N<sup>o</sup> de neurônios, N<sup>o</sup> de parâmetros, MSE e R<sup>2</sup> das amostras de treino e validação

Grid Search						
N <sup>o</sup> de neurônios			1	2	3	4
N <sup>o</sup> de parâmetros			7	14	21	28
R <sup>2</sup>	$c'$	Treino	0,79	0,82	0,81	0,85
		Validação	0,68	0,72	0,85	0,72
	$\phi'$	Treino	0,65	0,78	0,87	0,85
		Validação	0,73	0,78	0,86	0,88
MSE	$c'$	Treino	$6,72 \cdot 10^{-3}$	$5,64 \cdot 10^{-3}$	$4,95 \cdot 10^{-3}$	$4,69 \cdot 10^{-3}$
		Validação	$5,23 \cdot 10^{-3}$	$5,68 \cdot 10^{-3}$	$4,95 \cdot 10^{-3}$	$4,03 \cdot 10^{-3}$
	$\phi'$	Treino	$1,03 \cdot 10^{-2}$	$6,32 \cdot 10^{-3}$	$4,21 \cdot 10^{-3}$	$4,26 \cdot 10^{-3}$
		Validação	$7,97 \cdot 10^{-3}$	$7,23 \cdot 10^{-3}$	$3,79 \cdot 10^{-3}$	$4,41 \cdot 10^{-3}$

Fonte: Autor

A análise do gráfico do R<sup>2</sup> pelo número de neurônios na camada oculta, conforme nos mostra a figura 4.1, apresenta um ganho significativo no desempenho para uma rede MLP de até 3 neurônios para o ângulo de atrito efetivo. Na análise para o intercepto coesivo efetivo pode-se notar um ligeiro ganho até o total de 4 neurônios.

Figura 4.1 – Coeficiente de Determinação (R<sup>2</sup>) pelo número de neurônios na camada oculta




Fonte: Autor



A análise do gráfico do MSE (figura 4.2) confirmou a melhora no desempenho para o ângulo de atrito efetivo, em verde, apresentando a melhor relação entre ganho de performance e número de parâmetros para uma quantidade de 3 neurônios. Na análise do MSE para o intercepto coesivo efetivo o desempenho continua crescente para uma rede com até 4 neurônios.

Figura 4.2 – *Mean Square Error* (MSE) pelo número de neurônios na camada oculta




Fonte: Autor

Os resultados das redes neurais MLP apontam que para melhor desempenho de estimativa e efeito de generalização para o banco de dados pode ser adotada para a rede neural do intercepto coesivo efetivo uma arquitetura com uma camada oculta e um total de 4 neurônios. A avaliação da arquitetura ideal para o ângulo de atrito efetivo indica que o desempenho desejável é alcançado com 3 neurônios na camada oculta.

A avaliação do treinamento foi realizado de maneira individual, através da análise da curva de treinamento do *Mean Square Error* pelo número de *epochs* das redes neurais. A etapa objetiva avaliar a convergência e verificar a possibilidade de ocorrência do *overfitting*. Na curva do intercepto coesivo efetivo, conforme figura 4.3, pode-se perceber que o MSE da amostra de validação performa ligeiramente acima da amostra de treino, o que pode significar um leve ajuste dos resultados a pontos ruidosos. O treinamento da rede neural MLP de 4 neurônios é finalizado quando alcançada 112 *epochs* pelo critério de número máximo sem mudanças.

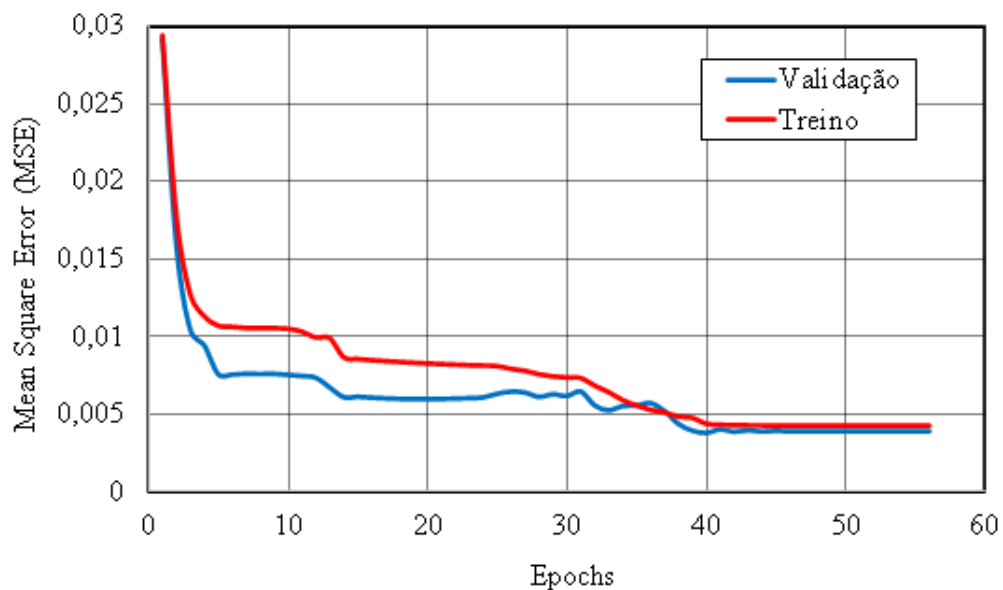
Figura 4.3 –  $c'$  - *Mean Square Error* pelo número de *epochs*



Fonte: Autor

A análise da curva de treinamento do *Mean Square Error* pelas *epochs* para o ângulo de atrito efetivo, conforme a figura 4.4, nos revela a melhor performance da amostra de validação em relação a de treino. A melhoria do desempenho continuam a crescer nas 14<sup>a</sup> e 37<sup>a</sup> *epoch*. O resultado, assim como no caso do intercepto coesivo efetivo pode ser efeito do ajuste indesejável. O fim do treinamento é atingido com 55 *epochs* pelo critério de número máximo.

Figura 4.4 –  $\phi'$  - *Mean Square Error* pelo número de *epochs*

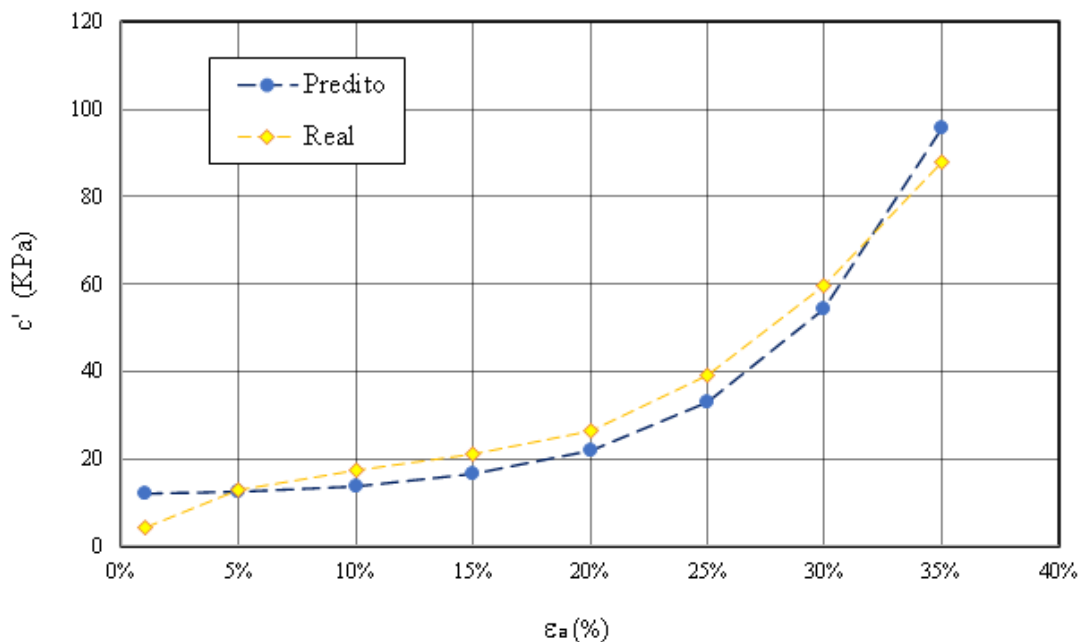


Fonte: Autor

As redes neurais definidas para o intercepto coesivo e ângulo de atrito efetivos foram em seguida analisadas em função dos resultados preditos e do desempenho geral do  $R^2$  e MSE para todo o conjunto de dados. A análise dos valores preditos para as redes neurais MLP foi interpretada em função da deformação axial específica pela importância destacada na literatura de RSU. O objetivo da análise do gráfico dos valores preditos e reais em função da deformação axial específica é sobretudo mostrar a aderência do modelo e nos revelar onde estão concentrados a maioria dos erros.

A resposta da rede neural com 4 neurônios para o intercepto coesivo efetivo para a amostra total dos dados (anexo C) resultou no  $R^2$  de 0,84 e um MSE de 175,3. Na avaliação da amostra AM2 – A4I<sub>2</sub>, conforme figura 4.5, pode-se constatar a aderência do modelo da rede neural treinada e o ajuste de tendência falhando em captar apenas o ponto de menor deformação axial específica.

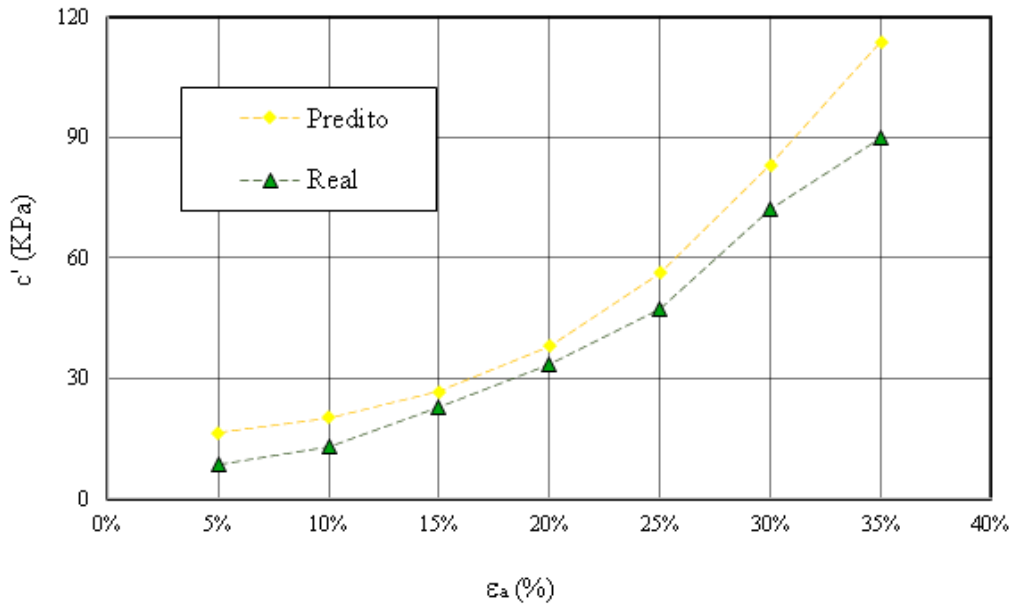
Figura 4.5 – MLP - GOMES (2008) AM2- -  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

Nos resultados das amostras de [Carvalho \(1999\)](#) nota-se um bom ajuste da rede neural MLP as amostras ensaiadas em geral. Na amostra do corpo de prova T2B12sat (figura 4.6) a aderência e a concentração dos erros não demonstra existência de viés de estimação, sendo obtido uma média de erro de cerca de 30% para os valores estimados.

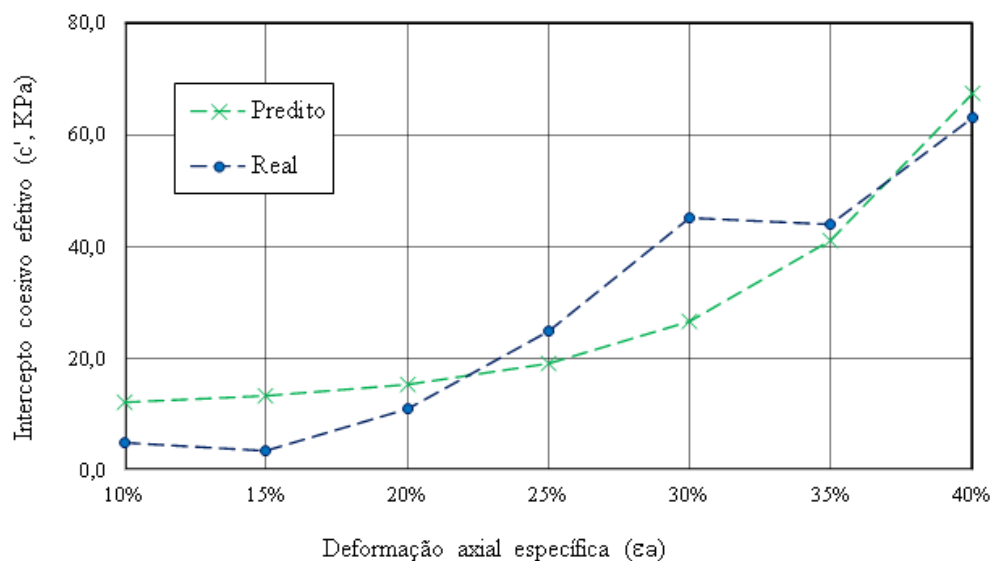
Figura 4.6 – MLP - CARVALHO (1999) - T2B12sat -  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

A análise dos ensaios reais e valores preditos possibilitou algumas constatações que podem ser atribuídas aos ruídos presentes nos dados coletados. Na amostra dos resultados de [Grisolia \*et al.\* \(1995a\)](#) (figura 4.7) por exemplo, pode-se reparar que para o ponto de deformação axial específica de 30% o resultado estimado diverge em 41% do valor real obtido pelo autor. Os demais valores preditos seguem a tendência bem ajustada à curva suave.

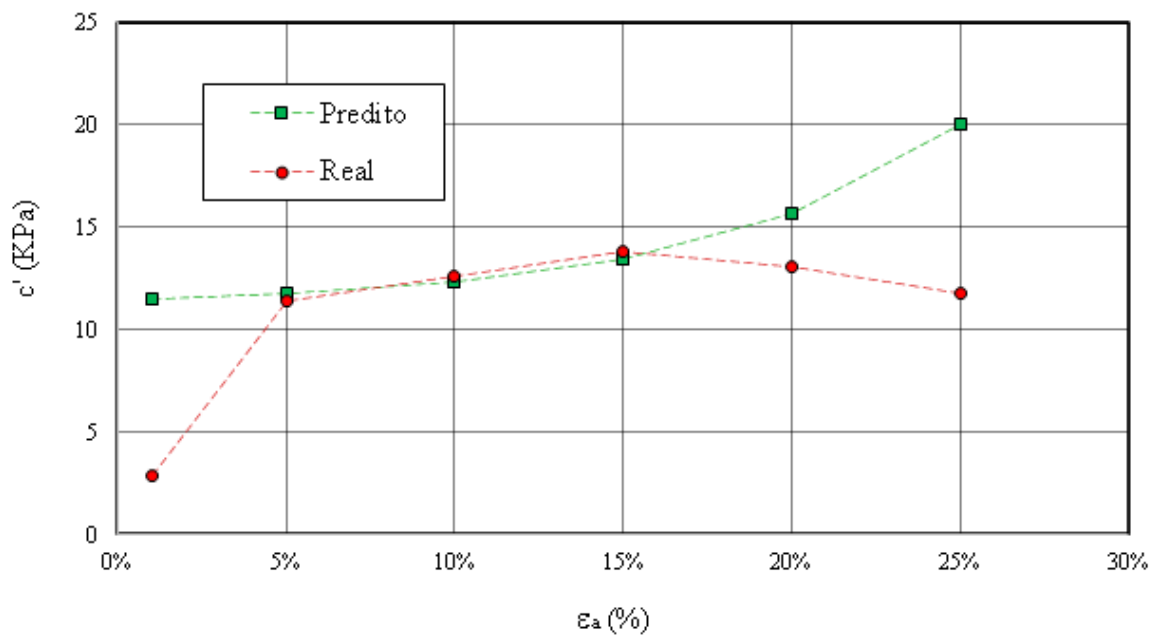
Figura 4.7 – MLP - GRISOLIA (1995) -  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

A avaliação dos erros das amostras revela padrões de falha em níveis de deformação extremos e na tendência dos valores reais. Na avaliação da amostra AM3 – B1I<sub>2</sub> de Gomes (2008), por exemplo, (figura 4.8) notou-se um desvio da tendência de mobilização do intercepto coesivo efetivo. No nível de deformação  $\varepsilon_a = 1\%$ ,  $\varepsilon_a = 20\%$  e  $\varepsilon_a = 25\%$  os erros alcançados são respectivamente de 296%, 19,2% e 69,9% do valor real obtido. A estimativa apontada indicaria crescimento progressivo, no entanto, há uma tendência de crescimento com estabilização e ligeira redução com a maior deformação axial específica.

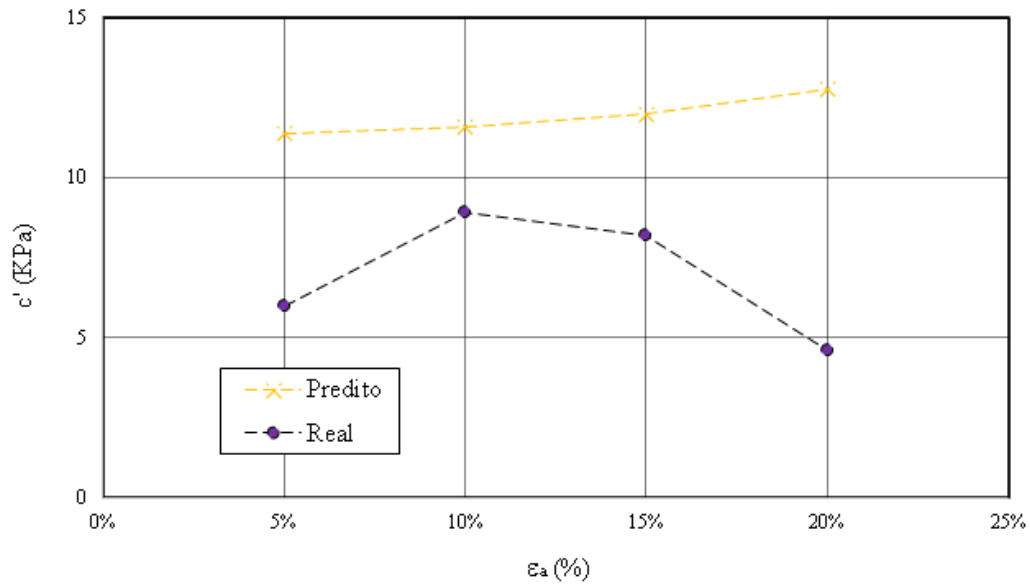
Figura 4.8 – MLP - GOMES (2008) - AM3 – B1I<sub>2</sub> -  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

A amostra de Nascimento (2007) denominada por 4anosCD10sat (figura 4.9) expõe outras ocorrências dos erros obtidos em níveis extremos. O caso mais crítico, no qual há o desvio dos valores e da tendência observada para as estimativas da rede MLP de 4 neurônios treinada, ocorrem para  $\varepsilon_a = 5\%$  e  $\varepsilon_a = 20\%$ . Os resultados para os níveis de deformação de 5 e 20% correspondem, respectivamente, a erros de 89,8% e 177,3% em relação aos dados reais obtidos.

Figura 4.9 – MLP - NASCIMENTO (2007) - 4anosCD10sat -  $c'$ (kPa) x  $\varepsilon_a$  (%):  
Real x Predito



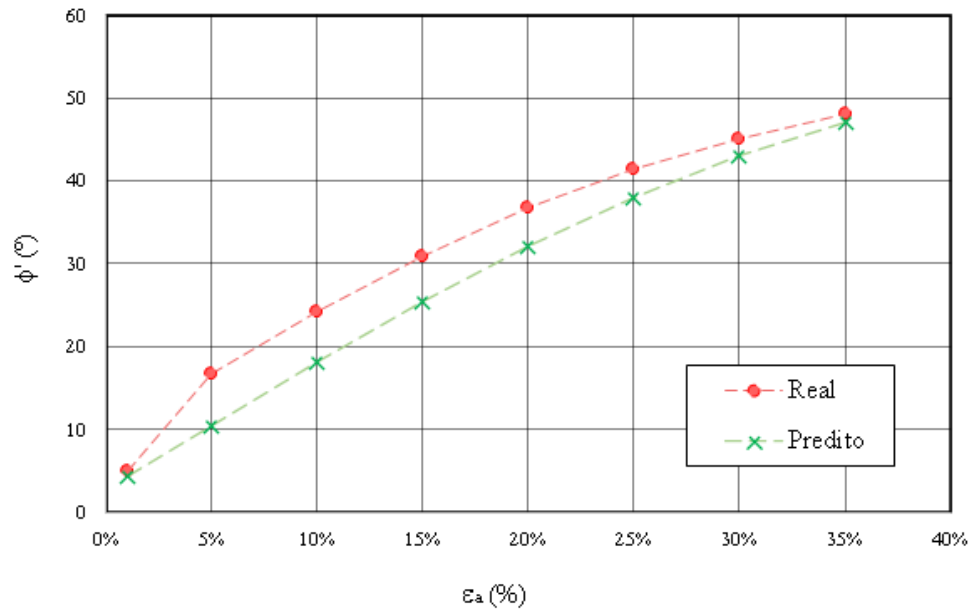
Fonte: Autor

No final, o resultado dos valores preditos de intercepto coesivo efetivo da rede neural MLP de 4 neurônios, para os conjuntos de ensaios que compõem o banco de dados, foram mais satisfatórios, principalmente, para os ensaios realizados por [Gomes \(2008\)](#), [Carvalho \(1999\)](#) e [Grisolia \*et al.\* \(1995b\)](#). Nos demais dados estimados a rede performava de maneira correspondente às medidas de avaliação utilizadas para a amostra total dos dados.

A avaliação dos resultados que performaram abaixo do conjunto de dados revela padrões de erros que permitem a orientação sobre possíveis causas. Nos ensaios de [Nascimento \(2007\)](#), [Hossain e Haque \(2009\)](#), [Machado \*et al.\* \(2005\)](#) e [Reddy \*et al.\* \(2009a, 2009b, 2011, 2015\)](#) houve pelo menos um valor predito no qual os resultados não são inteiramente satisfatórios. No conjunto de dados mal estimados se tem entre característica comum resíduos novos, altos percentuais de material orgânico e constituintes de fibras.

A rede neural MLP de 3 neurônios, definida para o ângulo de atrito efetivo, obteve para a amostra total dos dados um  $R^2$  de 0,88 e um MSE de 16,2 (anexo C). Na avaliação da amostra AM2 – A4I<sub>2</sub> (figura 4.5) notou-se a estimativa aproximadamente uniforme da rede neural treinada e o ajuste suave em função da deformação axial específica.


Figura 4.10 – MLP - GOMES (2008) AM2 – A4I<sub>2</sub> -  $\phi'(^{\circ})$  x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

Na amostra T1B12nat de [Carvalho \(1999\)](#) (figura 4.11), nota-se a boa adesão do modelo à tendência dos valores reais. Os valores preditos se distanciaram ligeiramente mais rápido nos níveis de  $\varepsilon_a = 30\%$  e  $\varepsilon_a = 35\%$ , sendo observados, respectivamente, erros de 23,1 e 24,2%. A aderência a tendência é suave e uniforme para os dados estimados.


Figura 4.11 – MLP - CARVALHO (1999) - T1B12nat -  $\phi'(^{\circ})$  x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

A avaliação do resultado obtido em função da deformação axial específica, semelhantemente ao demonstrado para o intercepto coesivo efetivo, permitiu a constatação de desvios em relação aos dados reais que podem caracterizar a presença de ruídos. No trabalho de [Grisolia \*et al.\* \(1995b\)](#) (figura 4.12), percebeu-se o distanciamento da tendência para o ângulo de atrito efetivo no nível de  $\varepsilon_a = 25\%$  e a formação de dois arcos. Os resultados estimados representam um ajuste suave aos dois arcos estabelecidos.

Figura 4.12 – MLP - GRISOLIA (1995) -  $\phi'(^{\circ})$  x  $\varepsilon_a$  (%): Real x Predito




Fonte: Autor

Na distribuição dos erros encontrados nas estimativas para os ensaios, ocorreu uma concentração no maior nível de deformação para parcela das amostras. No ensaio realizado por [Carvalho \(1999\)](#) para o corpo de prova T2B12nat (figura 4.13), constata-se a ocorrência de erros maiores nos níveis de  $\varepsilon_a = 25\%$  e  $\varepsilon_a = 30\%$ , sendo obtidos erros de 62,8% e 71,1%. Os erros nos níveis mencionados A tendência indicada aponta crescimento progressivo, enquanto o obtido em ensaio indica crescimento com ligeira queda e estabilização.



Figura 4.13 – MLP - CARVALHO (1999) - T2B12nat -  $\phi'(\alpha) \times \varepsilon_a$  (%): Real x Predito



Fonte: Autor

O resultado da rede neural MLP com 3 neurônios treinada para o ângulo de atrito efetivo demonstrou um ajuste adequado para maior parte dos dados. Os melhores resultados são observados para o conjunto de dados de [Gomes \(2008\)](#), [Carvalho \(1999\)](#) e [Grisolia \*et al.\* \(1995b\)](#). O resultado menos satisfatório foi o obtido para a amostra T2B12nat de [Carvalho \(1999\)](#). No geral, as estimativas correspondem ao obtido para as medidas de avaliação da rede treinada, sendo percebido para os valores preditos uma menor quantidade de erros em relação ao intercepto.

#### 4.1.3 Redes Neurais Extreme Learning Machine

A modelagem foi realizada utilizando uma rede neural ELM para intercepto coesivo e ângulo de atrito efetivos, visando uma melhor aproximação dos resultados preditos. A definição do número de neurônios é a única variável a ser definida para a rede neural ELM. O número de neurônios foi avaliado pelo *grid-search* dentro do limite de 6 até o máximo de 27 neurônios.

A realização do *Grid-search*, conforme tabela 4.2, mostra uma boa performance das redes neurais ELM para os valores preditos no geral. O resultado do MSE entre as amostras de treino e validação difere em até 60% tanto para o intercepto coesivo quanto para o ângulo de atrito. O  $R^2$  entre as amostras de treino e validação das duas saídas têm

uma diferença máxima de 18% entre as amostras. Nas redes neurais ELM o desempenho também é aperfeiçoado com o acréscimo de neurônios, porém, diferentemente das redes MLP, o número de parâmetros cresce mais lentamente.


Tabela 4.2 – *Grid-search* rede neural ELM: N° de neurônios, N° de parâmetros, MSE e R<sup>2</sup> das amostras de treino e validação

Grid Search						
N° de neurônios			6	13	20	27
N° de parâmetros			7	14	21	28
R <sup>2</sup>	c'	Treino	0,60	0,69	0,80	0,79
		Validação	0,66	0,75	0,79	0,80
	φ'	Treino	0,68	0,74	0,84	0,86
		Validação	0,59	0,71	0,78	0,85
MSE	c'	Treino	1,12.10 <sup>-2</sup>	8,48.10 <sup>-3</sup>	5,88.10 <sup>-3</sup>	5,88.10 <sup>-3</sup>
		Validação	5,45.10 <sup>-3</sup>	4,45.10 <sup>-3</sup>	3,56.10 <sup>-3</sup>	3,56.10 <sup>-3</sup>
	φ'	Treino	8,91.10 <sup>-3</sup>	7,08.10 <sup>-3</sup>	4,68.10 <sup>-3</sup>	4,11.10 <sup>-3</sup>
		Validação	6,68.10 <sup>-3</sup>	5,16.10 <sup>-3</sup>	3,53.10 <sup>-3</sup>	2,23.10 <sup>-3</sup>

Fonte: Autor

A análise gráfica para o coeficiente de determinação (R<sup>2</sup>) concedeu a definição da quantidade aceitável para o número de neurônios. O desempenho da rede neural ELM apresenta ganho significativo, conforme mostra a figura 4.14, para uma rede até 20 neurônios tanto para o ângulo de atrito efetivo e intercepto coesivo efetivo.


Figura 4.14 – Coeficiente de Determinação (R<sup>2</sup>) pelo número de neurônios



Fonte: Autor

A análise do gráfico do MSE, conforme a figura 4.15, pode confirmar que o número ideal de neurônios é de 20 para o intercepto coesivo e para o ângulo de atrito efetivos. A tendência estabelecida aponta que o MSE para o ângulo de atrito efetivo continua a diminuir com o acréscimo de neurônios, porém a justificativa mais provável para esta redução deve ser atribuída ao ajuste dos pontos ruidosos, sendo por isso desconsiderada.


Figura 4.15 – *Mean Square Error* (MSE) pelo número de neurônios



Fonte: Autor

A rede neural ELM definida para o intercepto coesivo efetivo apresenta um  $R^2$  de 0,79 e um MSE de 235,2 para a estimativa da amostra total dos dados (anexo D). Na avaliação da amostra AM2 – A4I<sub>2</sub>, conforme figura 4.16, identificou-se o ajuste do modelo da rede neural treinada aos dados reais por uma curva suave e o maior distanciamento ocorrendo para o valor predito no nível de deformação de 5%.


Figura 4.16 – ELM - GOMES (2008) AM2 – A4I<sub>2</sub>:  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

No resultado da amostra AM3 – B1I<sub>2</sub> percebeu-se para a rede neural ELM, similar ao obtido para a MLP, distanciamento da tendência observada. Os dados obtidos cresceram em menor intensidade, enquanto os preditos seguem uma tendência maior e contínua de crescimento. Os pontos que incidem maiores erros são os níveis de  $\varepsilon_a = 20\%$  e  $\varepsilon_a = 25\%$ , sendo observado um erro de até 287% para os valores reais.

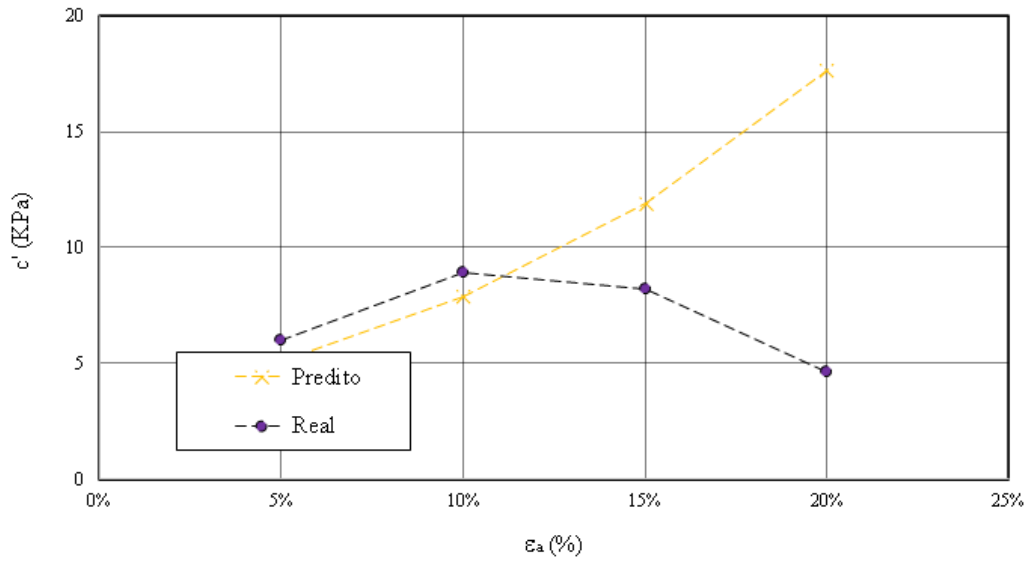
Figura 4.17 – ELM GOMES (2008) - AM3 -  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

Na amostra 4anosCD10sat de Nascimento (2007) observou-se um desvio similar da tendência da rede neural ELM em relação a MLP. No geral os pontos mais extremos de  $\varepsilon_a = 15\%$  e  $\varepsilon_a = 20\%$  que concentraram erros de 45,5% e 284%, ocorrendo divergência também em sua tendência.

Figura 4.18 – ELM - NASCIMENTO (2007) - 4anosCD10sat -  $c'$ (kPa) x  $\varepsilon_a$  (%):  
Real x Predito




Fonte: Autor

O resultado para a rede neural ELM treinada com 20 neurônios para o intercepto coesivo efetivo, no geral, também, obtiveram melhores resultados para Carvalho (1999), Gomes (2008) e Grisolia *et al.* (1995b). Os erros percebidos nas estimativas de ensaios tendem a ser maiores do que aos observados para MLP para os maiores níveis de deformação. A rede ELM performa abaixo do esperado pelas medidas de avaliação para o conjunto de dados de Nascimento (2007), Hossain e Haque (2009), Machado *et al.* (2005) e Reddy *et al.* (2009a, 2009b, 2011, 2015).

A análise dos valores de ângulo de atrito efetivo para a rede neural ELM com 20 neurônios apresentaram ajustes suaves. A rede neural apresentou um  $R^2$  0,83 e um MSE de 22,4 (anexo D). Na amostra AM2 – A4I<sub>2</sub> de Gomes (2008) (figura 4.19) por exemplo, notou-se a aderência dos valores preditos da rede neural ELM com erros observados entre 10 e 20% para maioria dos níveis de deformação axial específica.


Figura 4.19 – ELM - GOMES (2008) - AM2 – A4I<sub>2</sub> -  $\phi'(^{\circ}) \times \varepsilon_a$  (%): Real x Predito



Fonte: Autor

O resultado da amostra T1B12nat de [Carvalho \(1999\)](#) (figura 4.20) expõe o ajuste mais uniforme para a rede neural ELM em comparação ao obtido pela MLP. No geral, a tendência observada para a amostra apresentou de maneira quase uniforme um erro de cerca de 28% para todos os níveis de deformação.


Figura 4.20 – ELM - CARVALHO (1999) - T1B12nat -  $\phi'(^{\circ}) \times \varepsilon_a$  (%): Real x Predito



Fonte: Autor

Na amostra ensaiada de [Grisolia \*et al.\* \(1995b\)](#) foi revelada a performance de generalização da rede neural ELM para os valores preditos (figura 4.21). A existência do ponto ligeiramente desajustado no nível de deformação de 25% evidenciou a adesão a tendência a curva suave. A tendência se distanciou da formação aproximada em arco no menor nível. No geral, os dados preditos diferiram em cerca de 10% dos valores reais em cada nível de deformação.

Figura 4.21 – ELM - GRISOLIA (1995) -  $\phi'(^{\circ})$  x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

O resultado da rede neural ELM com 20 neurônios para o ângulo de atrito efetivo é bem próximo ao obtido para a rede neural MLP, porém o efeito de generalização é ligeiramente maior nesta primeira. A consequência atribuída a generalização é o ajuste mais uniforme da tendência. O ensaio de [Carvalho \(1999\)](#) para a amostra T2B12nat, similarmente a rede MLP, não alcançou resultados inteiramente satisfatórios.

#### 4.1.4 Treinamento e Validação: *Least-Square Support Vector Regression*

A construção do modelo LS-SVR concedeu a estimativa para o intercepto coesivo e o ângulo de atrito efetivos de uma vez. A função kernel utilizada foi a sigmoideal, definida conforme tabela 2.4. A determinação dos valores das variáveis de regularização  $\gamma$  e da abertura da função kernel  $\sigma$  são as únicas incógnitas do algoritmo LS-SVR.

A determinação dos valores é feita por *global-random search*, através da geração

de 1 mil pares aleatórios dos parâmetros do algoritmo definidos no intervalo entre 0,001 e 10. Os pares são testados um a um em cada solução da equação linear definida na seção 2.5.3, pela forma  $\mathbf{AX} = \mathbf{B}$ , sendo posteriormente calculadas as estimativas, segundo equação (2.40) para as amostras de treino e validação. A cada iteração verifica-se a performance obtido pelo  $R^2$  e MSE, sendo observada melhoria no desempenho guardam-se os parâmetros  $\sigma$  e  $\gamma$  analisados.

O *global-random search*, conforme tabela 4.3, revelou a boa performance para as amostras, sendo evidenciada pela acurácia do modelo com divergência máxima de 2% para o  $R^2$  de treino e validação. O valor do MSE diverge cerca de 100% para as amostras de intercepto coesivo efetivo e em cerca de 44% para o ângulo de atrito efetivo. Na tabela 4.3 notou-se que os parâmetros do modelo LS-SVR tendem a limites extremos e o resultado obtido com estes não difere tanto entre o treino e validação. O tempo total de execução da busca do algoritmo foi de 219,49 segundos. O resultado, no geral, demonstrou uma ligeira demora e melhor desempenho dentre os métodos de aprendizado de máquina em geral, porém confirmou a maior dificuldade em modelar o intercepto coesivo efetivo.

Tabela 4.3 – *Global-random-search* LS-SVR: Parâmetros, limite inferior, superior, solução, MSE e  $R^2$  das amostras de treino e validação

Global Random Search			
Parâmetro	$\sigma$	Lmite inferior	0,001
		Limite superior	10,000
		Solução	0,015
	$\gamma$	Lmite inferior	0,001
		Limite superior	10,000
		Solução	9,479
$R^2$	$c'$	Treino	0,980
		Validação	0,991
	$\phi'$	Treino	0,970
		Validação	0,977
MSE	$c'$	Treino	0,002
		Validação	0,001
	$\phi'$	Treino	0,005
		Validação	0,003


Fonte: Autor



Os parâmetros do LS-SVR definidos pelo procedimento foram posteriormente utilizados para a estimativa da amostra total dos dados. Na estimativa da amostra total obteve-se para o intercepto coesivo um MSE de 9,94 e um  $R^2$  de 0,99 para os dados desnormalizados (anexo E).

O resultado obtido LS-SVR pode indicar um melhor desempenho para a amostra AM2 – A4I<sub>2</sub> evidenciado na figura 4.22. A adesão aos dados e a tendência é mais nítida, porém o erro para o primeiro e segundo nível de deformação axial específica,  $\varepsilon_a = 1\%$  e  $\varepsilon_a = 5\%$ , respectivamente, foram de 63,2 e 14,14%. Nos demais níveis de deformação o erro observado estão entre 1,7 e 7,8% do valor real.


Figura 4.22 – LS-SVR GOMES (2008) - AM2 – A4I<sub>2</sub>:  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

O desempenho do modelo LS-SVR para a amostra AM3 – B1I<sub>2</sub> de [Gomes \(2008\)](#) é melhor do que o obtido para redes neurais MLP e ELM. Na figura 4.23 percebeu-se que os dados reais aderem aos dados preditos em todos os níveis de deformação. O erro obtido é quase uniforme e fica em torno de 15% do valor real para todos os níveis de deformação axial específica.


Figura 4.23 – LS-SVR GOMES (2008) - AM3 – B1I<sub>2</sub>:  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

Na amostra 4anosCD10sat revelou-se a ligeira diferença dos dados reais a tendência. Os erros observados para os níveis de deformação  $\varepsilon_a = 5\%$  e  $\varepsilon_a = 20\%$  são, respectivamente, de 41,4% e 56,9% e são os maiores dentro do estimado para a amostra ensaiada por Nascimento (2007).

Figura 4.24 – LS-SVR - NASCIMENTO (2007) - 4anosCD10sat -  $c'$ (kPa) x  $\varepsilon_a$  (%): Real x Predito




Fonte: Autor

No total, a assertividade do LS-SVR para o intercepto coesivo efetivo é melhor para os mesmos grupamentos de ensaios das redes neurais. Os valores preditos subestimados ou superestimados são frequentemente os níveis de deformação axial específica abaixo de 5% ou acima de 20%, embora a intensidade dos erros diminuam significativamente. As estimativas dos ensaios de Haque (2007) e Hossain e Haque (2009), Machado *et al.* (2005), Nascimento (2007), Reddy *et al.* e (2009a, 2009b, 2011, 2015) ainda concentram boa parte dos maiores erros observados em níveis de deformação axial específica, porém a aderência a curva de tendência é atendida.

No total o resultado dos valores preditos do LS-SVR para o ângulo de atrito efetivo tem boa adesão aos dados e tendências, apresentando para os dados desnormalizados um  $R^2$  de 0,99 e um MSE de 1,14 (anexo E). Na amostra AM2 – A4I<sub>2</sub> (figura 4.25) se tem que o ajuste da tendência segue os dados reais, sendo observada uma divergência de cerca de 7% para maioria dos pontos. A maior diferença entre valor predito e real ocorre para o nível de deformação de 1%.


Figura 4.25 – LS-SVR GOMES (2008) - AM2 – A4I<sub>2</sub>:  $\phi_r$  '(°) x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

No resultado da amostra T1B12nat (figura 4.26) a acurácia é evidenciada pela aproximação uniforme a todos níveis de deformação axial específica, semelhantemente, ao obtido pela rede neural ELM. No total, notou-se um erro observado até cerca de 4% para todos os pontos e a confluência com os dados reais atendida.


Figura 4.26 – LS-SVR CARVALHO (1999) - T1B12nat:  $\phi_l '(\circ)$  x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

Nos resultados obtidos da amostra de [Grisolia \*et al.\* \(1995b\)](#) revelou-se a adesão ao ponto  $\varepsilon_a = 25\%$  que se distancia vagamente ao alinhamento da curva de tendência. O erro observado no ponto desalinhado é de 1,8%. O erro observado nos níveis  $\varepsilon_a = 1\%$  e  $\varepsilon_a = 40\%$  foram, respectivamente, de 13,7% e 3,9%, sendo o resultado deste primeiro nível o limite máximo dos erros obtidos para a amostra ensaiada.

Figura 4.27 – LS-SVR GRISOLIA (1995):  $\phi_l '(\circ)$  x  $\varepsilon_a$  (%): Real x Predito



Fonte: Autor

As estimativas do LS-SVR para o ângulo de atrito efetivo apontou uma melhor adesão as curvas de tendência e aos pontos observados, sendo visto, no geral, uma performance superior ao obtido pelas redes neurais. No geral a margem de erro para os dados observados é pequena e garante a acurácia dos dados preditos. Nos triaxiais realizados por [Carvalho \(1999\)](#), [Gomes \(2008\)](#) e [Grisolia \*et al.\* \(1995b\)](#) alcançou-se os menores erros. Nas amostras dos ensaios de [Carvalho \(1999\)](#) o modelo performou um pouco abaixo do desempenho esperado pelas medidas avaliadas.

## 4.2 Estudo de caso: aterro sanitário de Santo Tirso

Nesta seção apresenta-se uma demonstração prática com uma utilização de previsões do intercepto coesivo e ângulo de atritos efetivos de uma amostra de dados reais estudada por [Gomes \(2008\)](#). As amostras colhidas por furos de sondagem na encosta do aterro tiveram os ensaios de determinação das variáveis que compõe os dados de entrada realizados, porém os ensaios triaxiais não foram executados sobre a totalidade delas.

No final foi realizada uma estimativa do fator de segurança para uma representação específica do aterro, através do programa *Slide 6.0*, considerando a geometria e o perfil modelado. A análise do fator de segurança para a representação do aterro foi feita utilizando os dados ensaiados e as estimativas para campo das redes neurais ELM e MLP.

### 4.2.1 *Características gerais e histórico*

O aterro localizado em Santo Tirso, Portugal, teve seu processo de construção iniciado em 1995 onde anteriormente se localizava um lixão a céu aberto. A obra do aterro contemplou construções visando controle tecnológico, impactos ambientais e a expansão de deposição de novos RSU, intencionando atender a população dos municípios da Associação de Municípios do Vale do Ave (AMAVE). Estima-se que o aterro foi o destino de aproximadamente 700 mil toneladas de resíduos entre 1995 e 2005.

Figura 4.28 – Aterro de Santo Tirso na fase final de exploração

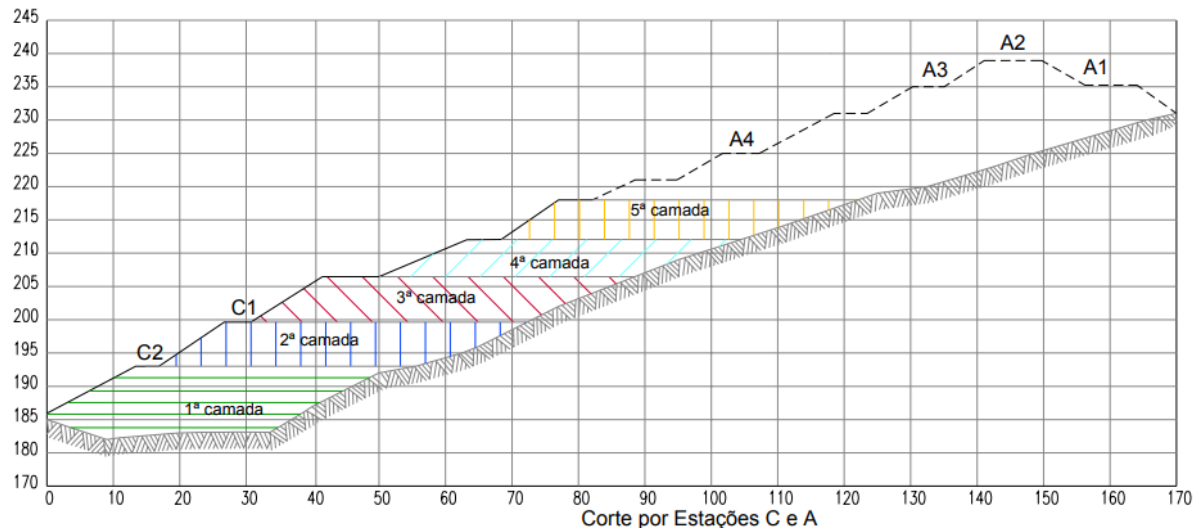


Fonte: (GOMES, 2008).

A construção do aterro acompanhou o perfil de encosta natural do relevo, sendo composta de dez camadas da base ao topo do terreno superior. A construção do aterro se iniciou a partir da cota de 185 metros se prolongando até a cota de 235 metros conforme figura 4.29. A inclinação dos taludes segue uma relação de 1:1,5 a 1:2 (V:H). A altura de cada talude alcança uma elevação de 4 a 6 metros e a distância da crista de um talude ao pé do talude superior se estende por cerca de 3 a 5 metros.

Gomes (2008) analisou o aterro, através de um plano de instrumentação e monitoramento abrangendo a avaliação dos deslocamentos totais superficiais e do corpo do aterro; estado de tensão; temperatura; níveis do lixiviado e o histórico construtivo. A instrumentação foi executada através da definição de estações: A; B e C e subestações: 1; 2; 3 e 4, sendo estes os pontos determinados de coletas (figura 4.29).

Figura 4.29 – Perfil transversal da área estudada por GOMES (2008)



Fonte: (GOMES, 2008).

#### 4.2.2 Coleta dos dados

Os dados coletados se referem as amostras dos furos de sondagens referentes a cada camada do aterro até a profundidade de amostragem. Os estudos conduzidos visaram determinar ou estimar as condições de campo relativas a composição gravimétrica, peso específico, umidade e tempo de decomposição para cada camada dos resíduos, sendo informadas no trabalho como dados de entrada conforme os anexos F e G.

Os ensaios triaxiais não foram realizados integralmente em todas as amostras coletadas. Nos dados de tensão de confinamento efetiva máxima e nível de deformação que são referentes as condições impostas sobre o corpo de prova foram necessárias algumas considerações a respeito dos estudos realizados.

Os níveis de deformação axial específica a serem identificados como dado de entrada para as amostras não ensaiadas precisaram ser estipulados, sendo adotados, basicamente, os mesmos das amostras ensaiadas com exceção dos níveis extremos aos quais o desempenho não foi adequado. Os níveis de deformação axial específica utilizados corresponderam ao intervalo entre 5 e 20%.

Nos níveis de tensão *in situ* do RSU, Gomes (2008) expõe que, via de regra, não são observados grandes valores para tensão de confinamento que frequentemente é inferior a 50kPa. Na estimativa dos valores, desejando-se alcançar resultados mais condizentes com os presentes em campo, adotou-se a tensão de confinamento máxima de 50kPa como

dado de entrada. Nos corpos de prova ensaiados a tensão de confinamento máxima, deformação axial específica, intercepto coesivo e ângulo de atrito efetivos são utilizados como comparação para uma nova aproximação.

No estudo do perfil do talude [Gomes \(2008\)](#) classificou os resíduos estudados, agrupandos pelo grau de decomposição em estágio avançado (estação C), intermediário (estação B) e recente (estação A). Os resíduos presentes nas 3 primeiras camadas foram produzidos durante os anos de 1995 e 1997 resultantes da mistura dos RSU presentes no lixão antigo, aqueles presentes nas demais camadas se subdividem entre os depositados nos anos de 1998 e 1999 e nos anos de 1999 até o fim de operação conforme apêndice D.

Na análise do perfil do aterro notou-se que as variantes do processo de coleta são a profundidade do furo de sondagem e o posicionamento das estações e subestações (apêndice E). No final foram colhidas mais de uma amostra para uma mesma camada, através do posicionamento de furos de sondagens de diferentes subestações, ocasionando na sobreposição do material coletado.

A sobreposição do material coletado das camadas (tabela 4.4) ocorre para as amostras das estações A e B e consistiu no compartilhamento de trechos de amostragem do aterro. No estudo do perfil geotécnico é possível observar que a maioria do material das amostras correspondem a trechos no intervalo de 4 a 5 metros numa tentativa de minimizar o efeito da coleta de RSU da vizinhança, sendo a altura aproximada de cada camada do aterro de Santo Tirso.



Tabela 4.4 – Resumo das amostras coletadas de RSU

Estação	Designação da amostra	Profundidade (m)	Camada
A	AM1	0 – 2	9
	AM2	0 - 1,2	9
	AM1 – A3I <sub>2</sub>	1 – 4,0	9
	AM2 – A3I <sub>2</sub>	4 – 9,0	8
	AM3 – A3I <sub>2</sub>	9 – 14,0	7
	AM1 – A4I <sub>2</sub>	1 – 4,0	7
	AM2 – A4I <sub>2</sub>	4 – 9,0	6
	AM3 – A4I <sub>2</sub>	9 – 14,0	5
B	AM1 – B1P <sub>1</sub>	1 - 6,0	7
	AM2 – B1P <sub>1</sub>	6 – 10,0	5
	AM1-B2P	1 – 6,0	5
	AM2-B2P	6 – 11,1	4
	AM1 – B1I <sub>1</sub>	1 – 6,0	7
	AM2 – B1I <sub>1</sub>	6 – 11,0	5
	AM1 – B1I <sub>2</sub>	1 – 6,0	7
	AM2 – B1I <sub>2</sub>	6 – 11,0	5
	AM3 – B1I <sub>2</sub>	11 – 14,2	4
	AM1 – B1P <sub>2</sub>	1 – 4,0	7
	AM2 – B1P <sub>2</sub>	4 – 8,0	7
	AM3 – B1P <sub>2</sub>	8 – 12,0	5
	C	AM1-C1P	1 – 6,0
AM2-C1P		7 – 11,0	1
AM3-C1P		12 – 14,0	1
AM1-C2P		1 – 5,0	1
AM2-C2P		5 – 9,8	1
AM1 – C2I <sub>2</sub>		1 – 5,0	1
AM2 – C2I <sub>2</sub>		5 – 10,0	1

Fonte: Adaptado de (GOMES, 2008).

#### 4.2.3 Caracterização geotécnica do perfil do aterro

Na representação do perfil do talude, para a estimativa do fator de segurança pela base de dados existentes, levou-se em consideração a semelhança das amostras das estações adotada por Gomes (2008). O conjunto de ensaios triaxiais executados referem-se as camadas 4, 5, 6 e 8, além do material das matrizes para A, correspondentes ao material

das camadas 4 a 7, e C que são os materiais das camadas 1 a 3.

Na representação do perfil foram consideradas válidas as propriedades do material coletado de uma camada correspondente a uma mesma estação quando não houve informações sobre demais amostras do conjunto. A amostra do triaxial da 8ª camada, por exemplo, foi considerada válida para a 9ª camada e as amostras da matriz de C coletadas foram atribuídas para a 1ª até a 3ª camada.

Na associação das amostras coletadas a cada camada, devido à ocorrência da sobreposição de material coletado, foi admitido como critério aquelas com maior extensão dentro da camada coletada e nenhum ou menor compartilhamento com outras camadas. Nas ocasiões onde uma camada pode ser descrita por mais de uma amostra coletada, foi feita uma divisão da camada e caracterização por esses materiais, visando obter uma maior variabilidade na representação do perfil.


Gomes (2008) não realizou a amostragem dos resíduos das 3ª e 10ª camadas. Os RSU da 3ª camada na representação do perfil, semelhantemente ao exposto para os ensaios que não foram executados, foram caracterizados pela amostra pertencente ao conjunto da estação C ao qual se enquadram.

Na representação da 10ª camada para o perfil do aterro, a solução foi modelá-la como um carregamento horizontal de 45 KN/m aplicado sobre o topo do aterro. O valor do carregamento foi obtido pelo cálculo da altura pelo peso específico do RSU. O peso específico admitido foi a média correspondente a faixa de resíduo com compactação ótima (tabela 2.3), estando dentro do intervalo de pesos específicos relatados no estudo.

No estudo analisado, não foi realizado uma investigação geotécnica do terreno de fundação da encosta do aterro que caracterizasse o peso específico natural, intercepto coesivo e ângulo de atrito efetivos. O solo de fundação foi representado como leito rochoso e a estabilidade do aterro avaliada em função dos resíduos depositados.

O nível do lixiviado no trabalho de Gomes (2008) foi monitorado através das estações e subestações identificadas. As alturas do lixiviado em relação a base de instalação variaram no intervalo de cerca de 2 a 12 metros de profundidade para todo o conjunto de leituras realizadas, enquanto para o topo a cota ficou em cerca de 14 metros. O nível do lixiviado empregado na representação do perfil foi o caso mais crítico de cerca de 2 metros de profundidade do topo de cada talude (figura 4.30) seguindo o relevo do terreno.

Figura 4.30 – Perfil transversal da representação do aterro de Santo Tirso



Fonte: Autor.

#### 4.2.4 Implementação das redes neurais ELM e MLP

A implementação das redes neurais para estimativa das saídas foram realizadas utilizando os pesos treinados para as entradas da seção 4.1. As entradas inseridas são normalizadas (equação 3.1) para o intervalo exposto em 3.2, e, após isso, transformados (equação 3.5), sendo novamente normalizados. As estimativas do intercepto coesivo e ângulo de atrito efetivos foram realizadas ao final desse processo (anexos F e G).

A coleta dos dados (seção 4.2.3) e as considerações feitas resultaram nos parâmetros inseridos no *Slide* (tabela 4.5). O critério de deformação utilizado é de 20% para  $c'$  e  $\phi'$ . A representação de cada camada foi realizada admitindo sua caracterização pelas amostras ensaiadas disponíveis no estudo analisado.

Tabela 4.5 – Dados geotécnicos e representação do perfil do aterro

Camada(s)	Designação da amostra adimitida	$\gamma_n$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$c'$ (kPa)	$\phi'$ (°)
8 e 9	AM2 – A3I <sub>2</sub>	9,42	20	26,60	36,80
6 e 7	AM2 – A4I <sub>2</sub>	7,68	20	21,40	36,10
5	AM2 – B1I <sub>2</sub>	9,60	20	27,20	38,40
4	AM3 – B1I <sub>2</sub>	12,76	20	13,10	43,00
1 e 3	Matriz C	12,67	20	21,60	33,40

Fonte: Adaptado de (GOMES, 2008).

Nas considerações do perfil geotécnico para a realização da análise de estabilidade, vale destacar a admissão dos dados da matriz C e o agrupamento das camadas 1 a 3. A representação da camada pela matriz dos resíduos foi considerada válida, ponderando que a resistência ao cisalhamento do RSU definido, apenas, pela matriz básica é subestimada, portanto estaria a favor da segurança.

Os dados estimados das redes neurais MLP para  $c'$  e  $\phi'$  foram definidos para o intervalo de níveis de deformação entre 5 e 20% (anexo F). O peso específico natural foi obtido analiticamente através das relações entre peso específico seco e umidade coletados, sendo utilizado juntamente aos demais dados geotécnicos. Na realização da análise de estabilidade no *Slide* foi adotado o critério de deformação para o nível de 20% (tabela 4.6).

Tabela 4.6 – Dados geotécnicos estimados e representação do perfil do aterro para a rede neural MLP

Camada(s)	Designação da amostra adimitida	$\gamma_n$ KN/m <sup>3</sup>	$\varepsilon_a$ (%)	$c'$ (kPa)	$\phi'$ (°)
9	AM1 – A3I <sub>2</sub>	10,20	20	14,94	42,65
8	AM2 – A3I <sub>2</sub>	12,11	20	14,90	31,79
7	AM3 – A3I <sub>2</sub>	13,13	20	16,96	33,17
6	AM2 – A4I <sub>2</sub>	12,65	20	17,68	33,12
5	AM1-B2P	11,52	20	17,60	33,84
4	AM2-B2P	11,52	20	18,05	30,97
3 e 2	AM1-C1P	10,56	20	11,08	56,73
1	AM2-C1P	11,78	20	13,53	53,52
1	AM1 – C2I <sub>2</sub>	12,99	20	16,21	50,71
1	AM1 – C2I <sub>2</sub>	13,55	20	14,87	52,15

Fonte: Autor.

Os dados das redes neurais ELM para  $c'$  e  $\phi'$  foram estimados para os mesmos níveis de deformação (anexo G). O critério de deformação utilizado, igualmente, as redes neurais MLP e aos dados ensaiados corresponde ao nível de 20%, sendo os demais dados geotécnicos representado segundo tabela 4.7.

Tabela 4.7 – Dados geotécnicos estimados e representação do perfil do aterro para a rede neural ELM

Camada(s)	Designação da amostra adimitida	$\gamma_n$ KN/m <sup>3</sup>	$\varepsilon_a$ (%)	$c'$ (kPa)	$\phi'$ (°)
9	AM1 – A3I <sub>2</sub>	10,20	20	8,03	54,71
8	AM2 – A3I <sub>2</sub>	12,11	20	9,73	53,92
7	AM3 – A3I <sub>2</sub>	13,13	20	14,19	55,24
6	AM2 – A4I <sub>2</sub>	12,65	20	15,19	49,79
5	AM1-B2P	11,52	20	17,10	59,70
4	AM2-B2P	11,52	20	16,44	51,83
3 a 2	AM1-C1P	10,56	20	9,98	53,65
1	AM2-C1P	11,78	20	10,67	58,24
1	AM1 – C2I <sub>2</sub>	12,99	20	14,87	58,01
1	AM1 – C2I <sub>2</sub>	13,55	20	11,66	58,17

Fonte: Autor.

Os resultados obtidos das redes neurais para  $c'$  e  $\phi'$  foram comparados entre si como forma de avaliar o desempenho da amostra para as entradas similares, porém externa ao conjunto de dados para as quais elas foram treinadas e validados. Os dados reais das estações estudadas definidas por [Gomes \(2008\)](#) serviram como uma média agregada dos resíduos das camadas, sendo utilizadas no comparativo para a estimativa das amostras estimadas.

Nas estimativas das redes neurais MLP, adotando os dados na tabela 4.5 como critério de comparação, foi observado um erro médio relativo de 26,6% abaixo do valor para  $c'$ . Os maiores erros relativos para  $c'$  foram de 44% obtido nas camadas 8 e 9 e o menor foi de 18% obtida para a camada 6. O erro médio relativo para  $\phi'$  foi de 18,4% acima dos dados ensaiados. Os maiores erros relativos percebidos foram de 70% para a camada 2 e 3 do aterro e os menores foram de 7,8% para a camada 6 e 7.

Nas estimativas das redes neurais ELM foi identificado um erro médio relativo de 39% abaixo do valor de  $c'$  para os dados ensaiados. Os maiores erros relativos para  $c'$  foram de 70% obtido nas camadas 8 e 9 e o menor foi de 25,5% obtida para a camada 4. O erro médio relativo para  $\phi'$  foi de 54,5% acima dos dados ensaiados. Os maiores erros relativos notados foram de 70% para a camada 2 e 3 do aterro e os menores foram de 20,5% para a camada 6 e 7.


As diferenças também foram comparadas para as duas redes neurais, sendo estendida a interpretação da performance. Os erros relativos para  $c'$  e  $\phi'$  foi, respectivamente, de 26,2% e 24,6%. Os resultados produzidos da rede neural MLP para  $c'$  são superestimados em relação à ELM, no entanto no observado para  $\phi'$  foram subestimados. No geral, os resultados seguem uma mesma tendência, apesar das diferenças notadas e, em relação ao dados ensaiados, a rede neural MLP apresenta melhor desempenho.

#### 4.2.5 Análise de estabilidade no Slide

A análise de estabilidade do perfil representado do aterro foi realizada utilizando o *Slide 6.0* para o critério de deformação definido. O método de cálculo do fator de segurança empregado para superfície de deslizamento foi Morgestern-Price. A razão da utilização do método é justificada pelas considerações do método a respeito do equilíbrio de forças e momentos; representação das forças interfáticas e sua variação na extensão da cunha.

A representação especificada do perfil do aterro de Santo Tirso no *Slide* (figura 4.31) para as redes neurais garantiram uma maior distribuição das amostras do perfil do aterro. A camada 3 é bem compartilhada por 3 amostras definidas no trabalho analisado.


Figura 4.31 – Representação do perfil no Slide para as redes neurais ELM e MLP



Fonte: Autor.

Na avaliação de estabilidade da representação considerada do perfil do aterro de Santo Tirso, apresentou-se para os dados coletados (tabela 4.5) um fator de segurança de 1,524 para deslizamento abrangendo as camadas 9 a 6. No resultado projetado notou-se uma superfície de ruptura circular com raio aproximado de 35 metros que engloba o topo até a base do relevo natural.

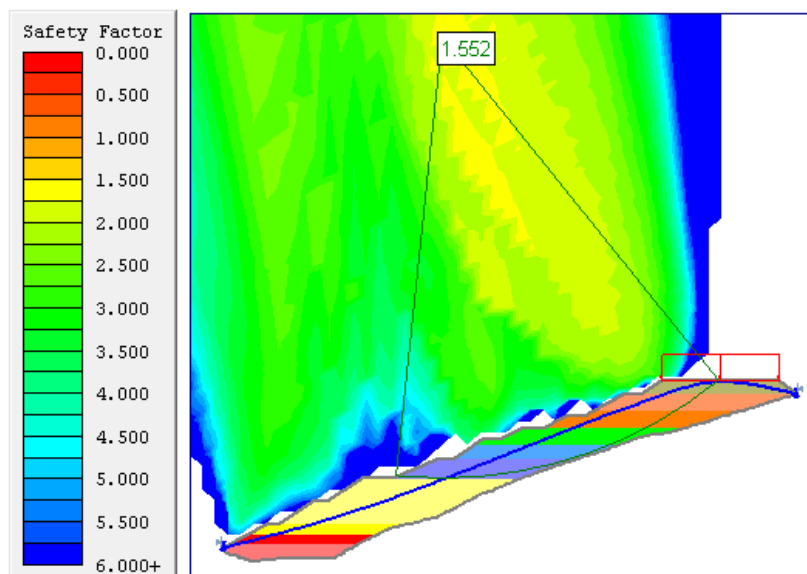
Figura 4.32 – Fator de segurança do perfil do aterro: dados coletados



Fonte: Autor.

Na avaliação para a aproximação obtida pela rede neural MLP constatou-se um fator de segurança 1,552 e uma envoltória de ruptura circular bem definida de 128 metros de raio (figura 4.33). A ruptura indicada pelos dados aproximados deve envolver as 9 camadas da representação estabelecida do perfil do aterro. No geral as diferenças do intercepto coesivo e ângulo de atrito efetivos admitidos para as camadas representadas resultam numa discrepância de 1,8% entre os fatores de segurança obtidos a partir dos dados reais e estimados.


Figura 4.33 – Fator de segurança do perfil do aterro: rede neural MLP



Fonte: Autor.

Na avaliação para a aproximação aferida pela rede neural ELM examinou-se um fator de segurança 1,541 e a formação da envoltória de ruptura circular bem delimitada (figura 4.34). O deslizamento relativo ao fator de segurança deve envolver as camadas 9 a 4 do perfil do aterro. No fator de segurança observou-se uma discrepância em torno de 1,1% para a referência com os dados reais adotados, enquanto a diferença para o intercepto coesivo e ângulo de atrito efetivos admitidos para as camadas ficou em cerca de 50%.

Figura 4.34 – Fator de segurança do perfil do aterro: rede neural ELM



Fonte: Autor.



A avaliação apontou que, até mesmo para uma maior divergência de intercepto coesivo e ângulo de atrito efetivos, como a que ocorre para a rede neural ELM, o resultado obtido para o fator de segurança é congruente com o projetado. O resultado obtido é um indicio de que a estimativa, contanto que sejam apresentadas condições de ajuste adequado a tendência e o modelo seja treinado e validado, pode ter utilidade prática.

## 5 CONCLUSÕES E TRABALHOS FUTUROS

Neste capítulo são expostas as conclusões dos objetivos definidos e as sugestões para realização de trabalhos futuros. Na seção 5.1 são discutidos o produto final do estudo e o atingimento dos objetivos. Na seção 5.2 são definidas propostas de complementaridade e aprimoramento do estudo.

### 5.1 Conclusões

No presente estudo foi realizado uma avaliação dentro do estado da arte de algoritmos de aprendizado de máquina. Na avaliação examinou-se o desempenho da aproximação para dados obtidos da literatura de ensaios triaxiais, expor as dificuldades da construção dos modelos e realizar a verificação das estimativas com uma finalidade prática na engenharia geotécnica.

Nas dificuldades de representar a composição gravimétrica, a determinação do sistema de classificação técnico de [Grisolia \*et al.\* \(1995a\)](#) foi uma ferramenta indispensável. A representação dos dados de maneira conjunta, considerando as propriedades dos materiais nas quais as classes pertencem, foi uma forma adequada de simplificar a características relevantes ao estudo dos RSU. Nos dados de entrada, via de regra, constatou-se a correlação entre as variáveis descritas que dificultam a mensuração da importância individual no conjunto de dados.

No geral foi revelada uma grande dificuldade em descrever a influência direta dos dados de entrada com o intercepto coesivo e ângulo de atrito efetivos. Os trabalhos na sua maioria definem os parâmetros da envoltória de Mohr-Coulomb por meio do critério de deformação e pela composição gravimétrica, destacando a parcela de material fibroso. Na base de dados coletadas, pela relevância aplicada nos trabalhos, a classe B do sistema de [Grisolia \*et al.\* \(1995a\)](#) e os níveis de deformação axial específicas são variáveis significativas para entender o comportamento.

A avaliação da influência do tempo de decomposição é pouco compreendida, embora existam estudos como [Nascimento \(2007\)](#), [Hossain e Haque \(2009\)](#), [Machado \*et al.\* \(2005\)](#) e [Reddy \*et al.\* \(2009a, 2009b, 2011, 2015\)](#) e [Kockel \*et al.\* \(1999\)](#) que o relacionem com o intercepto coesivo e o ângulo de atrito efetivos sobre o critério de deformação, porém não há descrições conclusivas sobre a sua influência. O efeito do tempo de decomposição

é explorado na literatura, também, numa análise conjunta da composição gravimétrica com o efeito de degradação do material fibroso. Os efeitos do peso específico e umidade dentro das pesquisas estudadas foram examinados principalmente por [Carvalho \(1999\)](#) e [Nascimento \(2007\)](#), tendo moldado diversos corpos de prova simulando diferentes condições de campo, no entanto a contribuição direta destas variáveis no intercepto coesivo e ângulo de atrito efetivos é pouco descrita.

O critério de deformação axial específica pelos modelos descritivos dos resíduos que compõem o RSU e a ausência de ruptura física nos estudos, torna-se indispensável. Os níveis de deformação relatados como referência são os maiores níveis capazes de causar grandes mobilizações, no entanto não há um só padrão de tendência observado. A tensão de confinamento, apesar de presente nos estudos se tem poucas informações.

No tratamento dos dados foi constatada a importância da análise descritiva, sendo possível identificar os ensaios nos quais obtemos *outliers* e entender como estes podem influenciar as estimativas. Na realização da análise de componentes principais foi confirmada a relevância que uma pequena parcela dos dados transformados acrescentam ao problema, sendo revelado que a variância do componente principal 1 sozinha corresponde a 52,73% da variância do conjunto, embora não tenha sido feita a identificação do componente principal para as variáveis de entrada. No trabalho apenas os 5 componentes principais respondem por um total de 93,62%. A redução da dimensão dos dados transformados aos elementos de maior variância auxiliou na redução da quantidade de parâmetros ajustáveis das redes neurais.

Nos resultados para os algoritmos de aprendizado de máquina avaliados notamos que a partir da base de dados transformada e reduzida ainda é possível realizar uma estimativa com bons ajustes às saídas coletadas e a tendência geral observada. Na determinação da arquitetura das redes neurais podemos confirmar a capacidade de aproximação de uma rede com apenas uma camada oculta, correndo menor risco de *overfitting* quanto menor a quantidade de neurônios e, portanto, parâmetros ajustáveis. As redes neurais consideradas durante o *grid-search* demonstram congruência para a quantidade de neurônios utilizados, no entanto torna-se inevitável ter parcimônia na escolha da rede.

Os resultados do algoritmo LS-SVR indicaram que é possível atingir bons resultados de estimação para as saídas coletadas. Os resultados devem refletir a existência de uma margem flexível estreita que englobam as saídas alvo. O algoritmo não serve, no

entanto para uma predição de dados desconhecidos devido aos multiplicadores de lagrange representarem uma solução única para cada dado de entrada.

A ocorrência dos desvios a tendência é um excesso de generalização que deve implicar numa menor quantidade de ensaios presentes nos dados. As características que representem o crescimento progressivo e estabilização podem conter dados ruidosos, como ocorreu com [Grisolia \*et al.\* \(1995b\)](#), que podem dificultar as estimativas produzidas para estes RSU. A , no entanto nos indica que dado ao tamanho da amostra de dados, a solução mais apropriada é o acréscimo de informações em detrimento ao de parâmetros ajustáveis.

As estimativas de intercepto coesivo efetivo demonstraram ser as variáveis mais difíceis de se aproximar, enquanto o ângulo de atrito efetivo revelou um bom ajuste aos dados e a tendência observada, ainda que também tenham sido constatados erros maiores para os níveis extremos. Os resultados para os métodos obtiveram performance dentro das medidas de avaliação para o ângulo de atrito efetivo, sendo que a amostra T2B12nat de [Carvalho \(1999\)](#) obteve desempenho menos satisfatório. Os resultados para o intercepto coesivo efetivo obtiveram as melhores aproximações para os trabalhos de [Gomes \(2008\)](#), [Carvalho \(1999\)](#) e [Grisolia \*et al.\* \(1995b\)](#), embora sejam percebidos ensaios abaixo do esperado pelas medidas de avaliação. Os erros de estimativas observados que compõem os estudos de [Nascimento \(2007\)](#), [Hossain e Haque \(2009\)](#), [Machado \*et al.\* \(2005\)](#) e [Reddy \*et al.\* \(2009a, 2009b, 2011, 2015\)](#) podem ser índice da importância do tempo de decomposição pela utilização comum de resíduos frescos. As amostras desses ensaios, onde os erros são observados representam dados abaixo de 1 desvio padrão da média para o tempo de decomposição, podendo este fator ter peso na baixa performance atingida. A influência do tempo de decomposição ter sido notado no intercepto coesivo efetivo tem congruência com o observado por [Kockel \*et al.\* \(1999\)](#) que indicou não serem constatados valor limite ao intercepto coesivo mobilizado com níveis crescentes de deformação.

No caso de estudo examinado foi observado para as duas redes neurais um padrão de subestimação do intercepto coesivo efetivo relativo à base de dados ensaiados, enquanto para o ângulo de atrito efetivo foi sobrestimado. As diferenças resultantes das aproximações, quando examinadas em relação ao fator de segurança obtidos pelos dados de referência, são diminuídas para no máximo 1,8%. Os resultados demonstram que a aproximação dos dados podem ter utilidade prática em análises em engenharia geotécnica desde que a adesão a tendência real seja confirmada.

A representação do perfil do aterro de Santo Tirso segue o esperado para os resíduos definidos pelas estações e subestações, segundo a descrição do perfil de aterro determinada por [Gomes \(2008\)](#). A representação do perfil das redes neurais não é exatamente a mesma, para o adotado como referência, por levar em consideração as estimativas dos resíduos caracterizados que não foram ensaiados por triaxiais. As considerações a respeito da matriz e do solo de fundação estão a favor da segurança, portanto as condições naturais presentes no aterro devem ser muito mais favoráveis.

## 5.2 Sugestão para trabalhos futuros

No decorrer da execução do trabalho foram identificadas possíveis ramificações ou extensões do estudo, visando o aprimoramento dos resultados expostos, nos quais se inserem os itens abaixo:

- avaliar outras alternativas ao sistema de classificação técnica de [Grisolia et al. \(1995a\)](#) na representação da composição gravimétrica como dado de entrada. Avaliar a possibilidade de utilização da composição dos materiais constituintes separadamente ou outro sistema técnico existente na literatura de RSU
- realização de uma análise completa dos dados de entrada que contemplem análise multivariada, análise de *clusters*, classificação de dados e possibilitem definir o grau de importância das variáveis
- executar uma análise completa dos dados de entrada para os *outliers* e comparar com os resultados para a amostra total
- avaliar o desempenho dos algoritmos com todas as combinações possíveis para as variáveis que compõe os dados de entrada
- avaliar o desempenho dos algoritmos com uma base de dados mais ampla, obtida de diversos outros tipos de ensaios de campo, laboratório e retroanálises
- analisar o desempenho do algoritmo LS-SVR e das redes neurais MLP e ELM com e sem os *outliers*
- avaliar a performance das técnicas de aprendizado de máquina com outros métodos de estimativa para o intercepto coesivo e ângulo de atrito efetivos

## REFERÊNCIAS

- ASADI, M.; SHARIATMADARI, N.; KARIMPOUR-FARD, M.; NOORZAD, A. Validation of hyperbolic model by the results of triaxial and direct shear tests of municipal solid waste. **Geotechnical and Geological Engineering**, v. 35, 04 2017.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. **NBR 10004**: Resíduos sólidos – classificação. Rio de Janeiro, 2004.
- ASTM. **ASTM D2974-13**: Test methods for moisture, ash, and organic matter of peat and other organic soils. West Conshohocken, PA, 2013.
- BABU, G. S.; CHOUKSEY, S. K.; LAKSHMIKANTHAN, P. Study of engineering properties of municipal solid waste of bangalore city. 12 2012.
- BORGATTO, A. V. A. **Estudo do efeito fibra e da morfologia na estabilidade de aterros de resíduos sólidos urbanos**. 157 p. Dissertação (Mestrado) — COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Fevereiro 2006.
- BRAY, J. D.; ZEKOS, D.; JR, E. K.; ATHANASOPOULOS, G. A.; RIEMER, M. F. shear strength of municipal solid waste. **Journal of geotechnical and geoenvironmental engineering**, American Society of Civil Engineers, v. 135, n. 6, p. 709–722, 2009.
- BRYSON, A. E.; HO, Y.-C. Book. **Applied optimal control; optimization, estimation, and control by Arthur E. Bryson, Jr. and Yu-Chi Ho**. [S.l.]: Blaisdell Pub. Co Waltham, Mass, 1969. 481 p. p.
- BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, Springer Science and Business Media LLC, v. 2, n. 2, p. 121–167, 1998.
- CAICEDO, B.; YAMIN, L.; GIRALDO, E.; CORONADO, O.; SOLER, N. Geomechanical properties of municipal solid waste in dona juana sanitary landfill. In: **Proceedings of the fourth international congress on environmental geotechnics, Brazil**. [S.l.: s.n.], 2002. v. 1, p. 177–182.
- CALLE, J. A. C. **Investigação dos Parâmetros de Resistência no Laboratório e no Campo de Resíduos Sólidos**. [S.l.], 2005.
- CALLE, J. A. C. **Comportamento Geomecânico de Resíduos Sólidos Urbanos**. 160 p. Tese (Doutorado em Engenharia Civil) — COOPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2007.
- CARDIM, R. D. **Estudo da resistência de resíduos sólidos urbanos por meio de ensaios de cisalhamento direto de grandes dimensões**. 107 p. Dissertação (Mestrado) — Faculdade de Tecnologia, Universidade de Brasília, Brasília, Janeiro 2008.
- CARVALHO, M. F. **Comportamento Mecânico de Resíduos Sólidos Urbanos**. 300 p. Tese (Doutorado em Engenharia Civil) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, 1999.

- CHEN, Y.-M.; LI, J.-C.; YANG, C.-B.; ZHU, B.; ZHAN, L.-T. Centrifuge modeling of municipal solid waste landfill failures induced by rising water levels. **Canadian Geotechnical Journal**, NRC Research Press, v. 54, n. 12, p. 1739–1751, 2017.
- DIXON, N.; JONES, D. R. V. Engineering properties of municipal solid waste. **Geotextiles and Geomembranes**, Elsevier BV, v. 23, n. 3, p. 205–233, jun. 2005.
- DUNCAN, J.; CHANG, C. Nonlinear analysis of stress and strain in soils. **Proc. Paper: J Soil Mech and Found Division ASCE**, v. 96, p. 1629–1653, 01 1970.
- EL-FADEL, M.; RASHED, H. Settlement in municipal solid waste landfills: I. field scale experiments. In: **The Thirteenth International Conference on Solid Waste Technology and Management**. Philadelphia: [s.n.], 1997. v. 2.
- FALAMAKI, A.; SHAHIN, S. Determination of shear strength parameters of municipal solid waste from its physical properties. **Iranian Journal of Science and Technology, Transactions of Civil Engineering**, Springer Science and Business Media LLC, v. 43, n. S1, p. 193–201, set. 2018.
- GABR, M.; VALERO, S. Geotechnical properties of municipal solid waste. **Geotechnical Testing Journal**, v. 18, p. 241–254, 1995.
- GOLDSTEIN, H. **Classical Mechanics (Addison-Wesley series in physics)**. [S.l.]: Addison-Wesley, 1980. ISBN 0201029189.
- GOMES, C. M. B. C. **Estudo do Comportamento de Aterros de Resíduos. Caracterização Física, Bioquímica e Mecânica dos Resíduos Sólidos Urbanos**. 536 p. Tese (Doutorado em Engenharia Civil) — Faculdade de Engenharia da Universidade do Porto, Universidade do Porto, 2008.
- GRISOLIA, M.; NAPOLEONI, Q.; TANGREDI, G. Contribution to a technical classification of msw. In: **Proceedings of the Fifth International Landfill Symposium, Sardinia '95**. Sardinia, Italy: [s.n.], 1995a. p. 705–710.
- GRISOLIA, M.; NAPOLEONI, Q.; TANGREDI, G. The use of triaxial tests for the mechanical characterization of municipal solid waste. In: **Proceedings of the Fifth International Landfill Symposium, Sardinia '95**. Sardinia, Italy: [s.n.], 1995b. p. 761–767.
- HAQUE, M. A. **Dynamic Characteristics And Stability Analysis Of Municipal Solid Waste In Bioreactor Landfills**. 149 p. Tese (Doctor of philosophy) — University of Texas at Arlington, 2007.
- HAYKIN, S. **Neural Networks - A Comprehensive Foundation, Second Edition**. 2. ed. [S.l.]: Prentice Hall, 1998. ISBN 9780132733502,0132733501.
- HAYKIN, S. O. **Neural Networks and Learning Machines**. 3rd edition. ed. [S.l.]: Prentice Hall, 2008. ISBN 0131471392,9780131471399.
- HOSSAIN, M. S.; HAQUE, M. A. The effects of daily cover soils on shear strength of municipal solid waste in bioreactor landfills. **Waste management**, Elsevier, v. 29, n. 5, p. 1568–1576, 2009.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: a new learning scheme of feedforward neural networks. In: **2004 IEEE International Joint Conference on Neural Networks (IEEE Cat. No.04CH37541)**. [S.l.]: IEEE, 2004.

JUNQUEIRA, F. F. **Análise de Comportamento de Resíduos Urbanos e sistemas Dreno-Filtrantes em diferentes escalas, com Referência ao aterro do Jóquei Clube**. 283 p. Tese (Doutorado) — Faculdade de Tecnologia, Universidade de Brasília, Brasília, 2000.

KAVAZANJIAN, E.; MATASOVIC, N.; BONAPARTE, R.; SCHMERTMANN, G. R. Evaluation of msw properties for seismic analysis. In: ASCE. **Proceedings of the Specialty Conference on Geotechnical Practice in Waste Disposal. Part 1 (of 2)**. [S.l.], 1995. p. 1126–1141.

KOCKEL, R.; KÖNIG, D.; SYLLWASSCHY, O. Three basic topics on waste mechanics. In: **International Conference on Soil Mechanics and Foundation Engineering**. [S.l.: s.n.], 1999. p. 1831–1837.

KÖLSCH, F. The bearing behaviour of domestic waste and related consequences for stability. In: **Proceedings of the Fourth International Landfill Symposium, Sardinia '93**. S Margherita di Pula, Cagliari, Italy: [s.n.], 1993. p. 1393–1410.

KÖLSCH, F. Material values for some mechanical properties of domestic waste. In: **Proceedings sardinia**. [S.l.: s.n.], 1995. v. 95, p. 20.

KÖLSCH, F. **Einfluss der Faserbestandteile auf die Scherfestigkeit von Siedlungsabfall**. Tese (Doutorado) — Leichtweiss-Institut für Wasserbau, Technische Universität Braunschweig, Germany, 1996.

KÖNIG, D.; JESSBERGER, H. L. Waste mechanics. **ISSMFE technical committee TC5 on environmental geotechnics**, p. 35–76, 1997.

LANDVA, A. O.; CLARK, J. I. Geotechnics of waste fill. In: **Geotechnics of waste fills—Theory and practice**. [S.l.]: ASTM International, 1990. ISBN 0-8031-1285-8.

LANGER, U.; DIXON, N. Mechanical properties of MSW: Development of a classification system. In: **GEOENVIRONMENTAL ENGINEERING**. [S.l.]: Thomas Telford Publishing, 2004. p. 267–274.

LEVENBERG, K. A method for the solution of certain non-linear problems in least squares. **Quarterly of Applied Mathematics**, American Mathematical Society (AMS), v. 2, n. 2, p. 164–168, jul. 1944.

MACHADO, S.; CARVALHO, M. d. F.; NASCIMENTO, J. d.; DOURADO, K. Estudo do comportamento mecânico de de resíduos sólidos urbanos sob a influência da biodegradabilidade. In: **23º Congresso Brasileiro de Engenharia Sanitária e Ambiental**. [S.l.: s.n.], 2005.

MACHADO, S. L.; CARVALHO, M. F.; VILAR, O. M. Constitutive model for municipal solid waste. **Journal of Geotechnical and Geoenvironmental Engineering**, American Society of Civil Engineers (ASCE), v. 128, n. 11, p. 940–951, nov. 2002. Disponível em: <[https://doi.org/10.1061/\(asce\)1090-0241\(2002\)128:11\(940\)](https://doi.org/10.1061/(asce)1090-0241(2002)128:11(940))>.



- MACHADO, S. L.; CARVALHO, M. F.; VILAR, O. M. *et al.* Towards modelling the municipal solid waste mechanical behaviour. In: INTERNATIONAL SOCIETY FOR ROCK MECHANICS AND ROCK ENGINEERING. **ISRM International Symposium**. [S.l.], 2000.
- MANASSERO, M.; IMPE, W. V.; BOUAZZA, A. Waste disposal and containment. state of the art report. **Proc. 2nd International Congress on Environmental Geotechnics, Osaka**, 1996.
- MANASSERO, M.; VAN IMPE, W. F.; BOUAZZA, A. Waste disposal and containment. In: **Environmental Geotechnics**. Balkema, Rotterdam: [s.n.], 1997.
- MANGASARIAN, O. L. **Nonlinear Programming**. [S.l.]: McGraw-Hill Book Company, 1969. ISBN 0070398852.
- MARQUARDT, D. W. An algorithm for least-squares estimation of nonlinear parameters. **Journal of the Society for Industrial and Applied Mathematics**, Society for Industrial & Applied Mathematics (SIAM), v. 11, n. 2, p. 431–441, jun. 1963.
- MCCORMICK, G. P. **Nonlinear Programming: Theory, Algorithms, and Applications**. USA: John Wiley & Sons, Inc., 1983. ISBN 0471093092.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The Bulletin of Mathematical Biophysics**, Springer Science and Business Media LLC, v. 5, n. 4, p. 115–133, dez. 1943.
- MILLER, W.; SCIENCES, U. of Florida. Department of E. E.; DEPARTMENT, U. of F. A. E.; SOLID, S. U. S. of Florida. Center for; MANAGEMENT, H. W. **Leachate Recycle and the Augmentation of Biological Decomposition at Municipal Solid Waste Landfills**. [S.l.]: State University System of Florida, Center for Solid and Hazardous Waste Management, 1991.
- MONTEIRO, V.; JUCÁ, J.; RÊGO, C. Influência das condições climáticas no comportamento do aterro de resíduos sólidos da muribeca. In: **Congresso de Engenharia Sanitária e Ambiental**. [S.l.: s.n.], 2001. v. 21.
- NASCIMENTO, J. C. F. do. **Comportamento mecânico de resíduos sólidos urbanos**. 160 p. Dissertação (Mestrado) — Escola de Engenharia de São Carlos, Universidade de São Paulo, São Paulo, 2007.
- OWEIS, I. S. Stability of landfills. In: **Geotechnical practice for waste disposal**. [S.l.]: Springer, 1993. p. 244–268.
- REDDY, K. R.; GANGATHULASI, J.; PARAKALLA, N. S.; HETTIARACHCHI, H.; BOGNER, J. E.; LAGIER, T. Compressibility and shear strength of municipal solid waste under short-term leachate recirculation operations. **Waste Management & Research**, Sage Publications Sage UK: London, England, v. 27, n. 6, p. 578–587, 2009a.
- REDDY, K. R.; HETTIARACHCHI, H.; GANGATHULASI, J.; BOGNER, J. E. Geotechnical properties of municipal solid waste at different phases of biodegradation. **Waste management**, Elsevier, v. 31, n. 11, p. 2275–2286, 2011.

REDDY, K. R.; HETTIARACHCHI, H.; GIRI, R. K.; GANGATHULASI, J. Effects of degradation on geotechnical properties of municipal solid waste from orchard hills landfill, usa. **International Journal of Geosynthetics and Ground Engineering**, Springer, v. 1, n. 3, p. 24, 2015.

REDDY, K. R.; HETTIARACHCHI, H.; PARAKALLA, N. S.; GANGATHULASI, J.; BOGNER, J. E. Geotechnical properties of fresh municipal solid waste at orchard hills landfill, usa. **Waste management**, Elsevier, v. 29, n. 2, p. 952–959, 2009b.

ROCHA NETO, A. R. Máquinas de vetores-suporte: uma revisão. **Learning & Nonlinear Models**, ABRICOM, v. 15, n. 1, p. 16–4, 2017.

RONG, F.; ZHAOGUI, G.; TUGEN, F. Analysis of stability and control in landfill sites expansion. **Procedia Engineering**, Elsevier, v. 24, p. 667–671, 2011.

ROSENBLATT, F. F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, p. 386–408, 1958.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, Springer Science and Business Media LLC, v. 323, n. 6088, p. 533–536, out. 1986. Disponível em: <<https://doi.org/10.1038/323533a0>>.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 1st. ed. [S.l.]: Prentice Hall, 1995. ISBN 0131038052, 9780131038059.

SANCHEZ-ALCITURRI, J.; PALMA, J.; SAGASETA, C.; CAÑIZAL, J. Mechanical properties of wastes in a sanitary landfill. In: **Symposium GREEN'93-Geotechnics related to the environment**. Bolton: [s.n.], 1993. p. 357–363.

SCHUELER, A. S. d. **Estudo de caso e proposta para classificação de áreas degradadas por disposição de resíduos sólidos urbanos**. 223 p. Tese (Doutorado) — COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Abril 2005.

SHARIATMADARI, N.; SADEGHPOUR, A.; MOKHTARI, M. Aging effect on physical properties of municipal solid waste at the kahrizak landfill, iran. **International Journal of Civil Engineering**, International Journal of Civil Engineering, v. 13, n. 1, p. 126–136, 2015.

SHARIATMADARI, N.; SADEGHPOUR, A. H.; RAZAGHIAN, F. Effect of aging on shear strength behavior of municipal solid waste. **International Journal of Civil Engineering**, 2013.

SIEGEL, R. A.; ROBERTSON, R. J.; ANDERSON, D. G. Slope stability investigations at a landfill in southern california. In: **Geotechnics of Waste Fills—Theory and Practice**. [S.l.]: ASTM International, 1990.

SILVEIRA, A. M. d. M. **Estudo do peso específico de resíduos sólidos urbanos**. 106 p. Dissertação (Mestrado) — COPPE, Universidade Federal do Rio de Janeiro, Rio de Janeiro, Março 2004.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, v. 14, n. 3, p. 199–222, ago. 2004. ISSN 1573-1375.

THOMAS, S.; ABOURA, A.; GOURC, J.; GOTTELAND, P.; BILLARD, H.; DELINEAU, T.; GISBERT, T.; OUYRY, J.; VUILLEMIN, M. An in situ waste mechanical experimentation on a french landfill. In: **7th International Landfill Symposium, Sardinia**. [S.l.: s.n.], 1999.

TURCZYNSKI, U. **Geotechnische Aspekte beim Aufbau von Mehrkomponentendeponien**. Tese (Doutorado) — Fakultat der technischen Wissenschaften, Bergakademie Freiberg, Germany, 1988.

VANDERBEI, R. J. **Linear Programming Foundations & Extensions**. Boston: Kluwer Academic, 1997.

VAPNIK, V. N. **The Nature of Statistical Learning Theory**. [S.l.]: Springer New York, 2000.

WU, G.; CHANG, E. Y.; PANDA, N. Formulating distance functions via the kernel trick. In: **Proceeding of the eleventh ACM SIGKDD international conference on Knowledge discovery in data mining - KDD '05**. [S.l.]: ACM Press, 2005.

ZHAN, T. L.; CHEN, Y.; LING, W. Shear strength characterization of municipal solid waste at the suzhou landfill, china. **Engineering Geology**, Elsevier, v. 97, n. 3-4, p. 97–111, 2008.

## APÊNDICE A – SCRIPTS DA REDE NEURAL MLP

### Código-fonte 1 – MLP.m

```

%%This work is licensed under a creative commons attribution 4.0
  International license

% Treina utilizando o metodo de Levenberg–Marquardt para aproximar
  pesos
% =====
% Rede Perceptron Multicamadas (MLP) – Arquitetura
% =====
clear; clc; close all;
format long;
pkg load statistics; addpath(genpath('Dados'));

load Entrada.mat; load Saida.mat;
% =====
%%      1. HIPERPARAMETROS E ARQUITETURA
% =====
%      1.1. Entradas
%

net.Y = Saida(:,1); load('PCA.mat'); net.X = Y(1:5,:);
%%      1.2. Numero de camadas e neuronios
%

net.neurons = [4, size(net.Y,2)];
%%      1.3. Hiperparametros da rede
% Epochs
net.epochs = 2000;
%% Parametro de damping/ Intervalo minimo damping/ Intervalo maximo
  damping
net.Mu = 1e-3; net.Mu_min = 1e-12; net.Mu_max = 1e+12;
%% Criterio de parada: minimo gradiente
net.min_grad = 1e-16;
% trainRatio/testRatio/valRatio
net.trainRatio = 0.8; net.testRatio = 0.2; net.valRatio = 0;
% frame rate
net.framerate = 10;

% =====
%      2. EXECUTA O TREINAMENTO DA REDE NEURAL
% =====
%%      2.1. TREINO, TESTE E VALIDACAO
%

[tr] = rncalc(net);

```

## Código-fonte 2 – rncalc.m

```

function [tr] = rncalc(net)
%   Atribui os Parametros da RNA MLP

neurons = net.neurons; Epochs = net.epochs;
MinGrad = net.min_grad; Mu = net.Mu; alfa = 1e-5;
framerate = net.framerate; j = 1; GradStop = 1;

[InputTrain, TargetTrain, InputTest, TargetTest, InputVal, TargetVal] =
    divideset(net);
%=====
% 1. Configura a RNA
%=====
% Inicia os pesos aleatorios
a = 0;
net.W1 = unifrnd(-a,a, neurons(1), size(net.X,2)+1); net.W2 = unifrnd
    (-a,a, neurons(2), neurons(1)+1);
%=====
% 2. TREINO: Inicia Treinamento por Epochs
%=====

tic;
while ( j<=Epochs) && (abs(GradStop) >= MinGrad)
fail = 0;
%=====
%% GRAFICOS: MSE e R2
%=====
if (j>2) && (rem(j, framerate) == 0)
n = 1;
Yt = TargetTrain; Ot = tr.train.Output;
plotarR2(Yt,Ot,n);
movegui('east');
n = 2;
Yt = TargetTest; Ot = tr.test.Output;
plotarR2(Yt,Ot,n); movegui('west');
figure(3);
plot(1:j-1, tr.train.MSE(1:j-1), 'b-', 1:j-1, tr.test.MSE(1:j-1), 'r-', 1:
    j-1, tr.val.MSE(1:j-1), 'g-');
xlabel('Epochs'); ylabel('MSE'); legend('Treino', 'Teste', 'Validacao');
movegui('north');
grid on
refresh;
end

X = [ones(size(InputTrain,1),1), InputTrain]; % k x N+1
Y = TargetTrain;

W1old = net.W1; W2old = net.W2; W = [W1old(:); W2old(:)];
[net] = feedforward(X,Y,net);

```

```

gdold = net.gd; Jold = net.J;
%% 2.1 Ajuste dos pesos e vieses na iteracao
% 2.1.1. Computa o custo inicial
%
erro = reshape(net.erro, [], 1); N = length(erro);
net.custo_old = erro'*erro/(2*N) + alfa/(2*N).*(W'*W); %% Funcao Custo:
    Mean Square Error na Epoch
while 1
%% 2.1.2. Altera os pesos na iteracao
%
W1 = net.W1; W2 = net.W2; W = [W1(:); W2(:)];
J = net.J; H = 1/N.*J*J';
Hinv = (H + Mu.*eye(size(H)))\eye(size(H));

W = W - Hinv*(net.gd - 1/N.*alfa.*W);

N1 = numel(net.W1); N2 = numel(net.W2);

net.W1 = reshape(W(1:N1,1), size(net.W1)); net.W2 = reshape(W(N1+1:N1+
    N2,1), size(net.W2));
%
% 2.1.3. Computa o custo final
%
    [net] = feedfoward(X,Y,net);

erro = reshape(net.erro, [], 1); N = length(erro);
net.custo = erro'*erro/(2*N) + alfa/(2*N).*(W'*W); %% Funcao Custo:
    Mean Square Error na iteracao
%
%% 2.1.4. Avalia e altera a constante de aproximacao da Hessiana
%
if fail<=1000
    if net.custo < net.custo_old
        Mu = Mu/10;
        if (Mu < net.Mu_min)
Mu = net.Mu_min;
            end
            break;
        else
            fail = fail + 1;
            Mu = Mu*10;
            net.W1 = W1old; net.W2 = W2old; net.gd = gdold; net.J = Jold;
            if (Mu > net.Mu_max)
Mu = net.Mu_max;
                end
            end
        else
            j = Epochs;
            break;
        end
    end

tr.train.MSE(j,:) = net.MSE; tr.train.R2(j,:) = net.R2;

```

```

tr.train.Gradient(j,:) = net.gradient; tr.train.Output = net.Output';
GradStop = net.gradient;

%=====
%% 3. TESTE: Inicia Teste por Epochs
%=====
X = [ones(size(InputTest,1),1), InputTest]; % k x N+1
Y = TargetTest;

[net] = feedfoward(X,Y,net);

tr.test.MSE(j,:) = net.MSE; tr.test.R2(j,:) = net.R2;
tr.test.Gradient(j,:) = net.gradient; tr.test.Output = net.Output';

%=====
%% 4. VALIDACAO: Inicia Validacao por Epochs
%=====
X = [ones(size(InputVal,1),1), InputVal]; % k x N+1
Y = TargetVal;

[net] = feedfoward(X,Y,net);

tr.val.MSE(j,:) = net.MSE; tr.val.R2(j,:) = net.R2;
tr.val.Gradient(j,:) = net.gradient; tr.val.Output = net.Output';

disp(['Epoch: ', num2str(j), ' Performance: ', num2str(net.custo), '
      Parametro de Damping:', num2str(Mu), ' R2:', num2str(tr.train.R2(j
      ,:))]);
j = j+1;
end

tr.elapsedTime = toc;

%=====
%% 5. Armazenamento do TREINO/TESTE/VALIDACAO: guarda performance,
      pesos, targets e inputs
%=====
Perf = [1./tr.train.MSE(2:end,:),tr.train.R2(2:end,:)];
bestPerf = max(Perf); [i,~] = find( bestPerf == Perf);
bestEpoch = i;

% training records (tr)
tr.W1 = net.W1; tr.W2 = net.W2;

tr.train.Input = InputTrain; tr.train.Target = TargetTrain;
tr.test.Input = InputTest; tr.test.Target = TargetTest;
tr.val.Input = InputVal; tr.val.Target = TargetVal;
tr.bestEpoch = bestEpoch;

end

```

## APÊNDICE B – SCRIPTS DA REDE NEURAL ELM

### Código-fonte 3 – ELM.m

```

%%This work is licensed under a creative commons attribution 4.0
  International license

clear; clc; close all;
load Entrada.mat; load Saida.mat;

pkg load statistics;

net.Y = Saida(:,1); % net.X = Entrada;
load('PCA.mat'); net.X = Y(1:5,:);

% neuronios 1 camada – Arquitetura
net.neurons = 27;
% trainRatio
net.trainRatio = 0.8; %% 80% treino
% testRatio }
net.testRatio = 0.0; %% 0% teste
% valRatio
net.valRatio = 0.2; %% 20% validacao

[net, tr] = elmcalc(net);

R2 = [tr.test.R2; tr.train.R2]
pathname = num2str(net.neurons(1)); filepath = strcat(pwd, '\ELM-',
  pathname);

n = 1;
Yt = tr.train.Target; Ot = tr.train.Output;
hold on
plotarR2(Yt,Ot,n);
movegui('west');

n = 2;
Yt = tr.test.Target; Ot = tr.test.Output;
hold on
plotarR2(Yt,Ot,n);
movegui('east');

save(fullfile(filepath, 'ELM.mat'), 'tr', 'net');
saveas(figure(2), fullfile(filepath, 'R2treino'), 'jpeg'); saveas(figure
(2), fullfile(filepath, 'R2teste'), 'jpeg');

```

### Código-fonte 4 – elmcalc.m



```

function [net, tr] = elmcalc(net)
[InputTrain, TargetTrain, InputTest, TargetTest, InputVal, TargetVal] =
    divideset(net);

neurons = net.neurons; % Number of hidden neurons
a= 1; net.W = unifrnd(-a,a,neurons,size(net.X,2)+1);

tic;
=====
%% 1. TREINO
=====
X = InputTrain'; % no bias
X = [ ones(1,length(X)); X]; % Include bias
Y = TargetTrain';

[net] = train(X,Y,net);

tr.train.MSE = net.MSE; tr.train.R2 = net.R2; tr.train.Output = net.
    Output';
=====
%% 2. TESTE
=====
X = InputTest'; % no bias
X = [ ones(1,length(X)); X]; % Include bias
Y = TargetTest';

[net] = simulate(X,Y,net);

tr.test.MSE = net.MSE; tr.test.R2 = net.R2; tr.test.Output = net.Output
    ';
=====
%% 3. VALIDACAO
=====
X = InputVal'; % no bias
X = [ ones(1,length(X)); X]; % Include bias
Y = TargetVal';

[net] = simulate(X,Y,net);

tr.val.MSE = net.MSE; tr.val.R2 = net.R2; tr.val.Output = net.Output';

tr.train.Input = InputTrain; tr.train.Target = TargetTrain;
tr.test.Input = InputTest; tr.test.Target = TargetTest;
tr.val.Input = InputVal; tr.val.Target = TargetVal;
tr.elapsedTime = toc;

end

```

## APÊNDICE C – SCRIPTS DO LS-SVR

Código-fonte 5 – LSSVR\_GRS.m

```

%%This work is licensed under a creative commons attribution 4.0
  International license
%% Titulo: Least Square – Support Vector Regression (LS–SVR)
%
% =====
% Least Square – Suport Vector Regression (LS–SVR) – Arquitetura
% =====
clear; clc; close all;
format long;
pkg load statistics

load Entrada.mat; load Saida.mat;
%
%% 1. Carrega os dados
%
net.Y = Saida;
net.X = Entrada;
% trainRatio
net.trainRatio = 0.8; %% 80% treino
% testRatio
net.testRatio = 0.2; %% 20% teste
% valRatio
net.valRatio = 0.0; %% 0% validacao

[InputTrain, TargetTrain, InputTest, TargetTest, InputVal, TargetVal] =
  divideset(net);

Lsuperior = [ 10 10 ];
Linferior = [0.001 0.001 ];
%
%% 2.1 EXECUTA O ALGORITMO
%
%
%% 2.1.1. Atribui os limites e a quantidade de valores aleatorios
%
Niteracao = 1000;

xbest = zeros(1,2);
aptidao = zeros(2*size(net.Y,2),Niteracao);

xbest(1,1:length(xbest)) = unifrnd(Linferior(1:length(Linferior)),
  Lsuperior(1:length(Lsuperior)));
param = xbest;
%% 2.1.2. Produz as solucoes candidatas no inetrvalo determinado
%

```

```

col = repmat(Lsuperior(1:length(Lsuperior)), Niteracao, 1);
lin = repmat(Linferior(1:length(Linferior)), Niteracao, 1);
xcand = unifrnd(lin, col);

%
%% 2.2. Determina a amostra de treino e a matriz de normas
%
Xt = InputTrain;
Yt = TargetTrain;

normij = pdist2(Xt,Xt, 'euclidean').^2;

kernel = 'rbf';
%
%% 3. Executa a busca – global random search
%
tic;
for t=1:Niteracao
    iteracao=t;

    [~, mse, Resultado, R2] = fobjetivo(param, kernel, normij, Xt, Yt);
    fbest = [R2 1./mse]; %% Avalia solucao inicial
    Resultadobest = Resultado;

    param = xcand(t,:);

    [~, mse, ~, R2] = fobjetivo(param, kernel, normij, Xt, Yt);
    fcand = [R2 1./mse]; %% Avalia solucao inicial
%
%% 3.1. Avalia se xcand produz melhor resultado que xbest
%
    if fcand>fbest
        xbest = xcand(t,:);
        fbest = fcand;
    else
        param = xbest;
    end

    aptidao(:,t)=fbest';
end
elapsedTime = toc;
% =====
%% 4. RESULTADOS: treino e teste c/ parametros ajustados
% =====
%
%% 4.1. TREINO
%
param = xbest;

[~, ~, Resultado, R2] = fobjetivo(param, kernel, normij, Xt, Yt);
train.Output = Resultado;
train.R2 = R2;
%

```

```
%% 4.2. TESTE
```

```
%
Xt = InputTest;
Yt = TargetTest;

normij = pdist2(Xt,Xt, 'euclidean').^2;

[ ~, ~, Resultado, R2] = fobjetivo(param,kernel, normij, Xt, Yt);
test.Output = Resultado;
test.R2 = R2;
```

```
% =====
```

```
%% 5. GRAFICOS
```

```
% =====
```

```
%
```

```
%% 5.1. Plotar Aptidao
```

```
%
figure(1);
plot( 1:1:t, aptidao(1,:), 'r-', 1:t,aptidao(2,:), 'b-');
xlabel('Iteration', 'FontSize', 16); ylabel('Fitness', 'FontSize', 16);
```

```
%
```

```
%% 5.2. Plotar R2
```

```
%
```

```
%% 5.2.1. TREINO
```

```
%
```

```
n = 2;
Xt = InputTrain;
Yt = TargetTrain;
Ot = train.Output;
plotarR2(Yt,Ot,n);
```

```
%
```

```
%% 5.2.2. TESTE
```

```
%
```

```
n = 3;
Xt = InputTest;
Yt = TargetTest;
Ot = test.Output;
plotarR2(Yt,Ot,n);
```

```
%
```

```
%% 5.2.3. SAIDAS: Plotar Coesao – angulo de atrito
```

```
%
```

```
n = 4;
Xt = InputTrain;
Yt = TargetTrain;
Ot = train.Output;
plotarSaidas(Xt,Yt,Ot,n);
```

## APÊNDICE D – PLANTA HORIZONTAL DE LOCALIZAÇÃO DA ÁREA ESTUDADA POR GOMES (2008)

Figura D.1 – Planta horizontal das estações e resíduos estudados

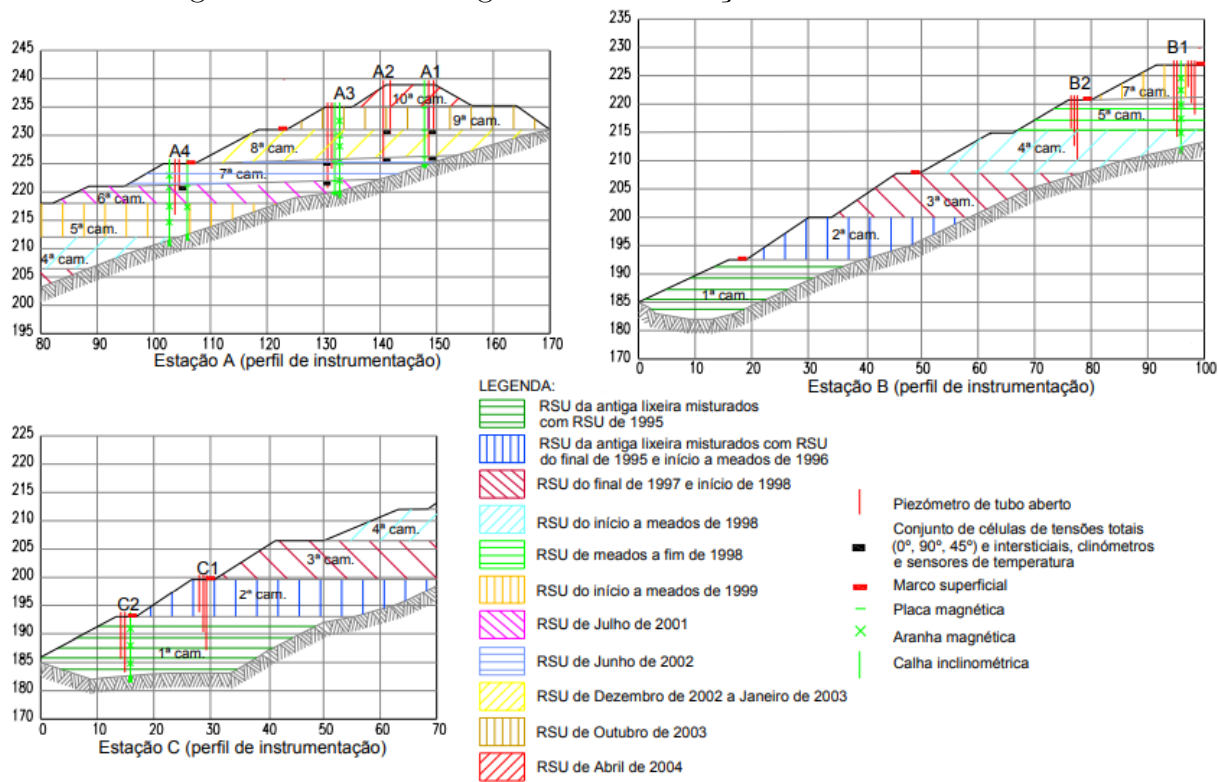
NOTA: Os resíduos da antiga lixeira foram misturados com RSU de 1995 e 1997.



Fonte: (GOMES, 2008).

## APÊNDICE E – PERFIL LONGITUDINAL DA ÁREA ESTUDADA POR GOMES (2008)

Figura E.1 – Perfil longitudinal das estações e resíduos estudados



Fonte: (GOMES, 2008).

ANEXO A – DADOS COLETADOS DA LITERATURA DE ENSAIOS TRIAXIAIS: ENTRADAS

Tabela A.1 – Dados de entrada coletados

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
GOMES (2008)	AM2 – A3I <sub>2</sub>	28,4	64,7	8,3	1,9	0,4	6,6	1	180
								5	
								10	
								15	
								20	
								25	
								30	
								35	
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
GOMES (2008)	AM2 – A4I <sub>2</sub>	18,7	71,1	7,1	4,0	0,4	5,9	1 5 10 15 20 25 30 35	135
GOMES (2008)	AM2 – ABI <sub>2</sub>	21,0	65,7	4,8	6,0	0,3	7,2	1 5 10 15 20 25	150
Continua									



**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
GOMES (2008)	AM3 – ABI <sub>2</sub>	37,5	50,3	5,8	6,0	0,3	7,9	1 5 10 15 20 25	140
GOMES (2008)	Matriz C	89,6	0,0	10,4	5,4	0,2	10,5	1 5 10 15 20 25	50
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
GOMES (2008)	Matriz A	95,5	0,0	4,5	9,4	0,2	9,9	1	150
								5	
								10	
								15	
								20	
25									
CARVALHO (1999)	T2A12nat	61,0	23,5	16,0	15,0	0,8	10,0	5	400
								10	
								15	
								20	
								25	
								30	
35									
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
CARVALHO (1999)	T2A12sat	61,0	23,5	16,0	15,0	0,7	10,5	5	400
								10	
								15	
								20	
								25	
								30	
								35	
CARVALHO (1999)	T2A10nat	61,0	23,5	16,0	15,0	0,6	9,2	5	400
								10	
								15	
								20	
								25	
								30	
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
CARVALHO (1999)	T2A14nat	61,0	23,5	16,0	15,0	0,7	11,0	5 10 15 20 25 30 35	400
CARVALHO (1999)	T2A12CUnat	61,0	23,5	16,0	15,0	0,6	11,5	10 20 30	273,5
CARVALHO (1999)	T2A12CUSat	61,0	23,5	16,0	15,0	0,7	10,6	10 20 30	87,1
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
CARVALHO (1999)	T1B12nat	61,0	23,5	16,0	15,0	0,5	10,9	5	400
								10	
								15	
								20	
								25	
								30	
35									
CARVALHO (1999)	T1B12sat	61,0	23,5	16,0	15,0	0,5	10,4	5	400
								10	
								15	
								20	
								25	
								30	
35									
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
CARVALHO (1999)	T1B12CUsat	61,0	23,5	16,0	15,0	0,6	13,7	10 20 30	178,1
CARVALHO (1999)	T2B12nat	61,0	23,5	16,0	15,0	0,4	11,9	5 10 15 20 25 30 35	400
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
CARVALHO (1999)	T2B12sat	61,0	23,5	16,0	15,0	0,4	12,0	5 10 15 20 25 30 35	400
CARVALHO (1999)	T2B12CU <sub>sat</sub>	61,0	23,5	16,0	15,0	0,4	8,6	10 20 30	175,6
CARVALHO (1999)	Matriz T2a	78,1	0,0	21,9	15,0	0,5	10,3	10 20	400
CARVALHO (1999)	Matriz T1b	78,1	0,0	21,9	15,0	0,6	9,6	10 20	400
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
CARVALHO (1999)	Matriz T2b	78,1	0,0	21,9	15,0	0,4	11,3	10 20	400
CARVALHO (1999)	T2a40CDnat	61,0	23,5	16,0	15,0	0,6	11,5	10 20 25	400
CARVALHO (1999)	T2a40CDsat	61,0	23,5	16,0	15,0	0,6	10,8	10 20 25	400
CARVALHO (1999)	T1b40CDsat	61,0	23,5	16,0	15,0	0,6	10,8	10 20 25	400
CARVALHO (1999)	T2b40CDsat	61,0	23,5	16,0	15,0	0,5	12,0	10 20 25	400
Continua									



**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
NASCIMENTO (2007)	NovoCD10sat	34,5	33,1	28,3	0,0	0,8	7,5	5 10 15 20	200
NASCIMENTO (2007)	NovoCD8sat	34,5	33,1	28,3	0,0	1,4	5,4	5 10 15 20	200
NASCIMENTO (2007)	NovoCU10sat	34,5	33,1	28,3	0,0	1,0	6,3	5 10 15 20	94 58,5 37,8 26,5
NASCIMENTO (2007)	4anosCD10sat	36,0	44,0	19,9	4,0	0,5	8,8	5 10 15 20	200
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
NASCIMENTO (2007)	4anosCD14sat	36,0	44,0	19,9	4,0	0,6	11,4	5 10 15 20	200
NASCIMENTO (2007)	4anosCU10sat	36,0	44,0	19,9	4,0	0,8	8,4	5 10 15 20	88,1 49,1 24,9 18,2
SHARIATMADARI <i>et al</i> (2013,2015)	SF	23,3	31,7	48,2	0,0	1,5	4,3	15	91,4
	S5	39,9	41,6	18,5	5,0	0,9	5,9	15	58,5
	S14	54,0	32,3	13,7	14,0	0,5	7,2	15	105,7
	S21	36,9	37,8	25,3	21,0	0,7	6,5	15	93,2
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
MACHADO <i>et al</i> (2005)	1	38,7	38,9	22,3	0,0	0,8	4,5	5 10 15 20 25	200
MACHADO <i>et al</i> (2005)	2	62,8	21,7	15,5	4,0	0,5	5,2	5 10 15 20 25	200
REDDY <i>et al</i> (2009)	1	41,4	40,0	18,6	0,0	0,4	6,0	15	276
	1	48,0	43,0	9,0	1,5	1,0	6,7	15	276
REDDY <i>et al</i> (2011)	1	40,0	25,0	35,0	0,0	1,0	5,6	15	276
REDDY <i>et al</i> (2015)	1	17,9	40,0	35,5	0,2	1,0	4,0	15	276
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
GRISOLIA <i>et al</i> (1995)	1,0	38,0	40,0	22,0	0,0	0,4	4,8	10	300
								15	
								20	
								25	
								30	
								35	
40									
HOSSAIN e HAQUE (2009) e HAQUE (2007)	RS1	13,6	70,6	16,0	0,1	1,5	3,6	20	207
		27,1	59,4	12,6	0,3	1,5	3,8	20	
		33,9	52,7	10,5	0,6	1,7	4,1	20	
		52,2	41,0	7,0	0,7	1,8	4,0	20	
HOSSAIN e HAQUE (2009) e HAQUE (2007)	RS2	30,0	57,9	12,1	0,1	1,2	4,6	20	207
		36,4	52,9	10,6	0,3	1,5	4,3	20	
		47,5	44,4	8,0	0,5	2,2	3,4	20	
		55,1	38,0	6,9	0,6	1,7	4,3	20	
Continua									

**Tabela A.1 – Dados de entrada coletados**

Autor(es)	Nº do ensaio ou designação da amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ ( $KN/m^3$ )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)
		A (%)	B (%)	C (%)					
HOSSAIN e HAQUE (2009) e HAQUE (2007)	RS2	36,5	52,9	10,6	0,1	1,2	5,1	20	207
		42,1	48,6	9,3	0,3	1,5	4,7	20	
		51,9	41,1	7,0	0,5	2,2	3,8	20	
		45,1	51,8	6,1	0,6	1,7	4,4	20	
ZHAN <i>et al</i> (2008) e RONG <i>et al</i> (2011)	LW4	40,0	42,0	16,0	1,7	0,8	5,3	10 20	400
	LW3	55,8	27,8	16,4	5,0	0,8	6,1	10 20	
	LW1	70,0	12,0	16,0	11,0	0,6	7,6	10	
BABU <i>et al</i> (2012)	1	30,1	35,4	33,1	0,1	0,4	6,9	20	150
CHEN <i>et al</i> (2017)	1	32,9	34,7	32,4	0,0	0,6	4,5	10 20	400
	2	55,8	27,8	16,4	5,0	0,5	6,2	10 20	
CAICEDO <i>et al</i> (2002)	1	7,5	44,7	47,8	1,0	0,7	5,4	15	200

**ANEXO B – DADOS COLETADOS DA LITERATURA DE ENSAIOS  
TRIAXIAIS: SAÍDAS DESEJADAS**

Tabela B.1 – Dados de saídas coletadas

Autor(es)	Tipo de Ensaio	Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)
GOMES (2008)	CD	AM2 – A3I <sub>2</sub>	4,2	5,0
			12,9	16,7
			17,6	24,2
			21,2	30,9
			26,6	36,8
			39,0	41,5
			59,5	45,0
			87,9	48,1
GOMES (2008)	CD	AM2 – A4I <sub>2</sub>	0,0	6,8
			0,0	19,7
			1,8	27,1
			9,4	31,9
			21,4	36,1
			39,9	39,9
			71,9	41,6
			105,8	43,9
GOMES (2008)	CD	AM2 – ABI <sub>2</sub>	5,6	0,0
			10,4	14,2
			21,0	20,9
			23,8	30,1
			27,2	38,4
			30,1	46,2
Continua				

Tabela B.1 – Saídas coletadas

Autor(es)	Tipo de Ensaio	Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)
GOMES (2008)	CD	AM3 – ABI <sub>2</sub>	2,9	8,5
			11,4	16,8
			12,6	27,8
			13,8	36,2
			13,1	43,0
			11,8	50,2
GOMES (2008)	CD	Matriz C	0,0	12,9
			4,0	22,9
			8,8	29,1
			14,6	32,3
			21,6	33,4
			31,9	33,1
GOMES (2008)	CD	Matriz A	0,0	12,9
			4,0	22,9
			8,8	29,1
			14,6	32,3
			21,6	33,4
			31,9	33,1
CARVALHO (1999)	CD	T2A12nat	8,6	18,0
			20,0	22,0
			30,2	25,7
			39,2	29,0
			54,2	31,0
			71,5	33,3
			111,8	33,0
Continua				

Tabela B.1 – Saídas coletadas

Autor(es)	Tipo de Ensaio	Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)
CARVALHO (1999)	CD	T2A12sat	15,0	14,5
			31,4	17,0
			47,1	19,5
			60,7	23,0
			73,0	27,0
			85,6	30,6
			97,4	34,7
CARVALHO (1999)	CD	T2A10nat	4,7	16,7
			19,5	19,0
			37,9	21,0
			60,2	22,0
			101,6	21,7
			115,4	24,0
CARVALHO (1999)	CD	T2A14nat	14,5	17,0
			33,3	20,0
			50,9	22,2
			74,9	24,3
			91,5	27,3
			121,7	29,0
			140,6	32,0
CARVALHO (1999)	CU	T2A12CU <sub>nat</sub>	37,0	20,5
			33,4	42,6
			48,5	53,0
CARVALHO (1999)	CU	T2A12CU <sub>sat</sub>	14,9	41,3
			49,7	48,5
			65,3	56,3
Continua				



Tabela B.1 – Saídas coletadas

Autor(es)	Tipo de Ensaio	Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)
CARVALHO (1999)	CD	T1B12nat	0,0	18,7
			9,9	23,0
			21,5	26,0
			37,6	28,4
			50,6	31,6
			68,1	33,8
			100,9	35,0
CARVALHO (1999)	CD	T1B12sat	5,5	17,0
			26,0	20,0
			44,5	22,5
			71,2	24,6
			99,5	26,5
			150,2	26,0
			196,0	26,6
CARVALHO (1999)	CU	T1B12CUSat	0,0	29,3
			0,0	44,8
			0,0	56,8
CARVALHO (1999)	CD	T2B12nat	22,1	8,7
			35,7	10,0
			38,9	13,0
			47,1	14,8
			73,4	13,9
			116,4	11,6
			145,8	11,3
Continua				

Tabela B.1 – Saídas coletadas

Autor(es)	Tipo de Ensaio	Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)
CARVALHO (1999)	CD	T2B12sat	8,7	14,0
			12,9	16,6
			22,7	17,7
			33,3	19,0
			47,2	19,5
			71,9	18,6
			89,9	18,4
CARVALHO (1999)	CU	T2B12CU <sub>sat</sub>	0,0	29,5
			0,0	44,1
			0,0	53,1
CARVALHO (1999)	CD	Matriz T2a	20,0	22,0
			33,1	27,3
CARVALHO (1999)	CD	Matriz T1b	36,5	21,3
			54,9	27,0
CARVALHO (1999)	CD	Matriz T2b	37,0	19,7
			44,1	25,8
CARVALHO (1999)	CD	T2a40CD <sub>nat</sub>	33,8	18,5
			73,8	22,0
			103,0	22,5
CARVALHO (1999)	CD	T2a40CD <sub>sat</sub>	18,3	18,3
			54,4	20,8
			78,7	21,3
CARVALHO (1999)	CD	T1b40CD <sub>sat</sub>	20,4	16,3
			47,3	20,8
			59,7	23,5
CARVALHO (1999)	CD	T2b40CD <sub>sat</sub>	23,3	12,3
			26,9	17,0
			30,7	19,0
Continua				

Tabela B.1 – Saídas coletadas

Autor(es)	Tipo de Ensaio	Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)
NASCIMENTO (2007)	CD	NovoCD10sat	6,8	14,8
			11,4	20,2
			17,6	24,2
			25,8	27,1
NASCIMENTO (2007)	CD	NovoCD8sat	0,7	13,9
			4,9	15,2
			11,2	17,5
			14,8	19,2
NASCIMENTO (2007)	CU	NovoCU10sat	0,6	28,6
			0,0	40,8
			0,0	50,2
			0,0	57,7
NASCIMENTO (2007)	CD	4anosCD10sat	6,0	14,3
			8,9	21,6
			8,2	27,7
			4,6	34,9
NASCIMENTO (2007)	CD	4anosCD14sat	9,6	14,3
			19,8	28,2
			26,0	33,9
			22,9	39,8
NASCIMENTO (2007)	CU	4anosCU10sat	13,4	28,8
			9,4	42,9
			0,0	58,5
			0,0	66,0
SHARIATMADARI <i>et al</i> (2013,2015)	CU	SF	25,0	24,8
		S5	11,2	45,8
		S14	12,2	34,1
		S21	16,1	30,8
Continua				

Tabela B.1 – Saídas coletadas

Autor(es)	Tipo de Ensaio	Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)
MACHADO <i>et al</i> (2005)	CD	1	4,2	16,3
			5,1	24,7
			2,0	31,8
			0,0	37,6
			0,0	42,4
MACHADO <i>et al</i> (2005)	CD	2	5,0	17,8
			12,3	22,2
			18,8	26,3
			27,5	29,4
			36,0	33,7
REDDY <i>et al</i> (2009)	CU	1	38,0	16,0
		1	34,0	23,0
REDDY <i>et al</i> (2011)	CU	1	18,0	11,0
REDDY <i>et al</i> (2015)	CU	1	42,0	13,0
GRISOLIA <i>et al</i> (1995)	CD	1	5,0	11,0
			3,5	24,0
			11,0	30,0
			25,0	33,0
			45,0	39,0
			44,0	43,0
HOSSAIN e HAQUE (2009) e HAQUE (2007)	CD	RS1	11,2	26,7
			20,5	26,7
			5,3	20,6
			2,4	19,0
Continua				

Tabela B.1 – Saídas coletadas

Autor(es)	Tipo de Ensaio	Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)
HOSSAIN e HAQUE (2009) e HAQUE (2007)	CD	RS2	22,3	29,0
			30,7	24,9
			13,7	23,2
			9,1	21,8
HOSSAIN e HAQUE (2009) e HAQUE (2007)	CD	RS2	24,5	33,1
			34,0	29,4
			13,1	26,4
			12,9	23,7
ZHAN <i>et al</i> (2008) e RONG <i>et al</i> (2011)	CD	LW4	21,6	9,6
			32,0	15,0
		LW3	23,0	18,0
			32,0	26,0
		LW1	0,0	29,5
BABU <i>et al</i> (2012)	CD	1	12,0	25,0
CHEN <i>et al</i> (2017)	CD	1	19,0	16,4
			22,0	26,4
		2	18,0	18,4
			24,0	28,6
CAICEDO <i>et al</i> (2002)	CU	1	45,0	14,0

ANEXO C – MLP: RESULTADOS DAS ESTIMATIVAS DA AMOSTRA TOTAL  
DOS DADOS

Tabela C.1 – MLP: resultados observados e preditos da amostra  
total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{preditto}$ (KPa)	$\phi'_{preditto}$ (°)
AM2 – A3I <sub>2</sub>	4,2	5,0	12,0	4,5
	12,9	16,7	12,5	10,5
	17,6	24,2	13,9	18,1
	21,2	30,9	16,6	25,4
	26,6	36,8	22,0	32,2
	39,0	41,5	32,8	38,1
	59,5	45,0	54,2	43,0
	87,9	48,1	95,6	47,1
AM2 – A4I <sub>2</sub>	0,0	6,8	12,0	9,2
	0,0	19,7	12,7	15,3
	1,8	27,1	14,2	22,9
	9,4	31,9	17,2	30,4
	21,4	36,1	23,2	37,2
	39,9	39,9	35,1	43,1
	71,9	41,6	58,7	48,2
	105,8	43,9	104,4	52,3
AM2 – ABI <sub>2</sub>	5,6	0,0	12,4	8,9
	10,4	14,2	13,3	15,1
	21,0	20,9	15,4	22,5
	23,8	30,1	19,6	29,5
	27,2	38,4	28,0	35,6
	30,1	46,2	44,7	40,7
Continua				

Tabela C.1 – MLP: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
AM3 – ABI <sub>2</sub>	2,9	8,5	11,5	15,4
	11,4	16,8	11,7	20,8
	12,6	27,8	12,3	28,0
	13,8	36,2	13,4	35,3
	13,1	43,0	15,6	42,3
	11,8	50,2	20,1	48,6
Matriz C	0,0	12,9	12,3	22,9
	4,0	22,9	12,9	24,0
	8,8	29,1	14,3	25,8
	14,6	32,3	16,7	28,1
	21,6	33,4	21,0	31,2
	31,9	33,1	28,5	35,1
Matriz A	0,0	12,9	12,0	20,2
	4,0	22,9	12,6	23,4
	8,8	29,1	13,7	28,0
	14,6	32,3	15,8	33,6
	21,6	33,4	19,1	40,0
	31,9	33,1	25,7	46,8
T2A12nat	8,6	18,0	18,5	14,9
	20,0	22,0	24,7	19,3
	30,2	25,7	35,4	22,9
	39,2	29,0	52,4	25,8
	54,2	31,0	75,3	28,2
	71,5	33,3	97,8	30,1
	111,8	33,0	112,0	31,6
Continua				

Tabela C.1 – MLP: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T2A12sat	15,0	14,5	18,5	15,3
	31,4	17,0	24,8	19,6
	47,1	19,5	35,8	23,0
	60,7	23,0	53,5	25,7
	73,0	27,0	78,5	27,8
	85,6	30,6	105,3	29,4
	97,4	34,7	124,9	30,6
T2A10nat	4,7	16,7	18,9	14,2
	19,5	19,0	25,6	18,7
	37,9	21,0	37,4	22,4
	60,2	22,0	56,8	25,4
	101,6	21,7	84,6	27,8
	115,4	24,0	116,2	29,8
T2A14nat	14,5	17,0	18,5	15,4
	33,3	20,0	24,6	19,4
	50,9	22,2	35,4	22,6
	74,9	24,3	52,7	25,0
	91,5	27,3	77,0	26,7
	121,7	29,0	103,2	28,0
	140,6	32,0	121,4	28,8
T2A12CU <sub>nat</sub>	37,0	20,5	17,5	27,6
	33,4	42,6	26,2	39,2
	48,5	53,0	44,7	47,1
T2A12CU <sub>sat</sub>	14,9	41,3	21,9	29,3
	49,7	48,5	39,3	41,9
	65,3	56,3	66,0	55,6
Continua				



**Tabela C.1 – MLP: resultados da amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T1B12nat	0,0	18,7	18,6	14,7
	9,9	23,0	25,0	18,6
	21,5	26,0	36,2	21,5
	37,6	28,4	54,6	23,6
	50,6	31,6	81,9	25,1
	68,1	33,8	114,3	26,0
	100,9	35,0	142,2	26,5
T1B12sat	5,5	17,0	18,7	15,2
	26,0	20,0	25,3	19,3
	44,5	22,5	37,0	22,5
	71,2	24,6	56,3	25,0
	99,5	26,5	85,1	26,9
	150,2	26,0	119,6	28,2
	196,0	26,6	150,3	29,1
T1B12CU <sub>sat</sub>	0,0	29,3	5,7	36,0
	0,0	44,8	-2,1	49,8
	0,0	56,8	1,5	61,0
T2B12nat	22,1	8,7	16,8	10,7
	35,7	10,0	21,1	13,7
	38,9	13,0	28,4	15,8
	47,1	14,8	40,7	17,3
	73,4	13,9	60,1	18,2
	116,4	11,6	86,9	18,9
	145,8	11,3	116,7	19,3
Continua				

**Tabela C.1 – MLP: resultados da amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T2B12sat	8,7	14,0	16,3	10,1
	12,9	16,6	20,1	13,1
	22,7	17,7	26,7	15,2
	33,3	19,0	37,9	16,6
	47,2	19,5	56,3	17,6
	71,9	18,6	83,0	18,3
	89,9	18,4	113,9	18,8
T2B12CUsat	0,0	29,5	12,9	31,4
	0,0	44,1	16,8	45,5
	0,0	53,1	29,2	57,3
Matriz T2a	20,0	22,0	30,9	18,5
	33,1	27,3	54,3	28,1
Matriz T1b	36,5	21,3	22,3	22,0
	54,9	27,0	42,6	30,4
Matriz T2b	37,0	19,7	38,9	18,1
	44,1	25,8	41,9	28,3
T2a40CDnat	33,8	18,5	23,9	17,8
	73,8	22,0	49,5	22,3
	103,0	22,5	71,8	23,6
T2a40CDsat	18,3	18,3	25,0	19,2
	54,4	20,8	54,4	24,7
	78,7	21,3	80,9	26,3
T1b40CDsat	20,4	16,3	24,8	19,5
	47,3	20,8	53,5	25,2
	59,7	23,5	78,7	27,0
T2b40CDsat	23,3	12,3	20,7	13,8
	26,9	17,0	39,4	17,5
	30,7	19,0	57,9	18,4
Continua				

Tabela C.1 – MLP: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
NovoCD10sat	6,8	14,8	11,2	12,7
	11,4	20,2	11,3	16,9
	17,6	24,2	11,3	22,0
	25,8	27,1	11,4	28,0
NovoCD8sat	0,7	13,9	11,2	10,2
	4,9	15,2	11,3	14,3
	11,2	17,5	11,3	19,3
	14,8	19,2	11,5	25,1
NovoCU10sat	0,6	28,6	11,2	26,6
	0,0	40,8	11,2	47,7
	0,0	50,2	11,2	54,4
	0,0	57,7	11,2	57,4
4anosCD10sat	6,0	14,3	11,4	15,1
	8,9	21,6	11,6	21,9
	8,2	27,7	12,0	29,1
	4,6	34,9	12,8	36,4
4anosCD14sat	9,6	14,3	11,4	17,6
	19,8	28,2	11,6	24,4
	26,0	33,9	11,9	31,6
	22,9	39,8	12,7	38,8
4anosCU10sat	13,4	28,8	11,2	22,8
	9,4	42,9	11,2	45,4
	0,0	58,5	11,2	57,5
	0,0	66,0	11,3	62,5
SF	25,0	24,8	11,2	26,8
S5	11,2	45,8	11,3	43,1
S14	12,2	34,1	11,9	36,3
S21	16,1	30,8	12,9	37,3
Continua				

Tabela C.1 – MLP: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
1	5,0	17,8	11,3	9,9
	12,3	22,2	11,4	15,0
	18,8	26,3	11,5	21,0
	27,5	29,4	11,9	27,7
	36,0	33,7	12,6	34,9
2	4,2	16,3	11,3	15,4
	5,1	24,7	11,4	20,6
	2,0	31,8	11,5	26,8
	0,0	37,6	11,9	33,6
	0,0	42,4	12,5	40,6
1	38,0	16,0	13,0	19,6
1	34,0	23,0	17,3	19,6
1	18,0	11,0	11,3	17,3
1	42,0	13,0	11,5	16,9
1	5,0	11,0	12,2	11,3
	3,5	24,0	13,2	18,1
	11,0	30,0	15,2	24,7
	25,0	33,0	19,1	30,8
	45,0	39,0	26,7	36,1
	44,0	43,0	41,0	40,5
	63,0	45,0	67,4	44,1
RS1	11,2	26,7	22,6	26,8
	20,5	26,7	19,1	24,5
	5,3	20,6	17,7	26,2
	2,4	19,0	15,4	28,5
Continua				

Tabela C.1 – MLP: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
RS2	22,3	29,0	18,2	25,2
	30,7	24,9	17,3	26,0
	13,7	23,2	16,0	32,3
	9,1	21,8	14,6	29,3
RS2	24,5	33,1	16,8	27,5
	34,0	29,4	16,2	27,6
	13,1	26,4	15,3	29,9
	12,9	23,7	19,9	27,3
LW4	21,6	9,6	21,2	8,2
	32,0	15,0	38,0	17,9
LW3	23,0	18,0	17,8	17,9
	32,0	26,0	34,2	28,4
LW1	0,0	29,5	16,5	27,8
1	12,0	25,0	11,3	26,3
1	19,0	16,4	11,3	15,6
	22,0	26,4	7,6	29,9
2	18,0	18,4	18,1	19,6
	24,0	28,6	36,2	30,0
1	45,0	14,0	11,2	17,1

**ANEXO D – ELM: RESULTADOS DAS ESTIMATIVAS DA AMOSTRA TOTAL  
DOS DADOS**

Tabela D.1 – ELM: resultados observados e preditos da amostra  
total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{preditto}$ (KPa)	$\phi'_{preditto}$ (°)
AM2 – A3I <sub>2</sub>	4,2	5,0	-1,7	9,4
	12,9	16,7	2,5	14,0
	17,6	24,2	9,1	20,0
	21,2	30,9	17,6	26,1
	26,6	36,8	28,2	32,1
	39,0	41,5	41,5	37,9
	59,5	45,0	57,7	43,3
	87,9	48,1	77,0	48,2
AM2 – A4I <sub>2</sub>	0,0	6,8	-6,3	12,1
	0,0	19,7	-0,5	16,9
	1,8	27,1	7,8	22,9
	9,4	31,9	17,5	29,0
	21,4	36,1	29,1	35,0
	39,9	39,9	42,8	40,8
	71,9	41,6	59,1	46,1
	105,8	43,9	78,3	50,9
AM2 – ABI <sub>2</sub>	5,6	0,0	-1,0	5,0
	10,4	14,2	4,1	10,7
	21,0	20,9	11,7	18,0
	23,8	30,1	21,0	25,2
	27,2	38,4	32,4	32,3
	30,1	46,2	46,3	39,0
Continua				

Tabela D.1 – ELM: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
AM3 – ABI <sub>2</sub>	2,9	8,5	3,1	14,3
	11,4	16,8	4,4	20,8
	12,6	27,8	7,8	28,8
	13,8	36,2	13,5	36,7
	13,1	43,0	22,1	44,3
	11,8	50,2	33,9	51,3
Matriz C	0,0	12,9	12,5	15,7
	4,0	22,9	8,1	21,1
	8,8	29,1	6,0	27,2
	14,6	32,3	8,2	32,5
	21,6	33,4	14,9	36,9
	31,9	33,1	26,5	40,3
Matriz A	0,0	12,9	-2,5	15,5
	4,0	22,9	-0,7	19,8
	8,8	29,1	6,0	24,7
	14,6	32,3	18,2	29,1
	21,6	33,4	35,8	32,6
	31,9	33,1	58,8	35,6
T2A12nat	8,6	18,0	16,0	17,2
	20,0	22,0	24,8	20,0
	30,2	25,7	37,2	22,5
	39,2	29,0	53,3	24,8
	54,2	31,0	73,3	26,7
	71,5	33,3	96,9	28,1
	111,8	33,0	124,1	29,0
Continua				

**Tabela D.1 – ELM: resultados da amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T2A12sat	15,0	14,5	15,3	15,7
	31,4	17,0	24,1	18,8
	47,1	19,5	36,5	21,6
	60,7	23,0	52,6	24,1
	73,0	27,0	72,5	26,3
	85,6	30,6	96,0	27,9
	97,4	34,7	123,1	28,9
T2A10nat	4,7	16,7	15,4	17,5
	19,5	19,0	24,1	20,4
	37,9	21,0	36,5	23,1
	60,2	22,0	52,7	25,5
	101,6	21,7	72,8	27,6
	115,4	24,0	96,6	29,2
T2A14nat	14,5	17,0	14,9	14,5
	33,3	20,0	23,8	17,8
	50,9	22,2	36,1	20,8
	74,9	24,3	52,2	23,4
	91,5	27,3	71,9	25,7
	121,7	29,0	95,4	27,4
	140,6	32,0	122,4	28,5
T2A12CU <sub>nat</sub>	37,0	20,5	8,8	22,0
	33,4	42,6	28,2	32,6
	48,5	53,0	62,2	40,5
T2A12CU <sub>sat</sub>	14,9	41,3	7,1	35,9
	49,7	48,5	12,3	50,6
	65,3	56,3	31,0	61,4
Continua				



**Tabela D.1 – ELM: resultados da amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T1B12nat	0,0	18,7	14,0	13,4
	9,9	23,0	22,9	16,9
	21,5	26,0	35,2	20,2
	37,6	28,4	51,2	23,2
	50,6	31,6	71,0	25,7
	68,1	33,8	94,4	27,7
	100,9	35,0	121,5	29,0
T1B12sat	5,5	17,0	14,4	14,7
	26,0	20,0	23,2	18,1
	44,5	22,5	35,6	21,2
	71,2	24,6	51,7	24,0
	99,5	26,5	71,6	26,4
	150,2	26,0	95,2	28,2
	196,0	26,6	122,4	29,5
T1B12CUsat	0,0	29,3	6,3	21,4
	0,0	44,8	15,6	37,2
	0,0	56,8	38,2	49,3
T2B12nat	22,1	8,7	13,1	9,8
	35,7	10,0	21,8	13,9
	38,9	13,0	34,0	17,7
	47,1	14,8	49,8	21,1
	73,4	13,9	69,2	24,1
	116,4	11,6	92,4	26,4
	145,8	11,3	119,2	28,1
Continua				

Tabela D.1 – ELM: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T2B12sat	8,7	14,0	13,0	9,5
	12,9	16,6	21,8	13,6
	22,7	17,7	33,9	17,5
	33,3	19,0	49,7	20,9
	47,2	19,5	69,1	23,9
	71,9	18,6	92,2	26,2
	89,9	18,4	118,9	28,0
T2B12CUsat	0,0	29,5	4,0	31,1
	0,0	44,1	17,8	43,2
	0,0	53,1	46,6	52,2
Matriz T2a	20,0	22,0	24,5	25,0
	33,1	27,3	54,7	22,6
Matriz T1b	36,5	21,3	25,1	24,0
	54,9	27,0	55,3	21,2
Matriz T2b	37,0	19,7	24,1	25,5
	44,1	25,8	54,2	23,5
T2a40CDnat	33,8	18,5	23,1	16,1
	73,8	22,0	51,2	22,4
	103,0	22,5	70,9	24,9
T2a40CDsat	18,3	18,3	23,3	17,6
	54,4	20,8	51,7	23,5
	78,7	21,3	71,5	25,9
T1b40CDsat	20,4	16,3	23,8	18,0
	47,3	20,8	52,2	23,7
	59,7	23,5	72,0	25,9
T2b40CDsat	23,3	12,3	22,0	14,0
	26,9	17,0	49,9	21,1
	30,7	19,0	69,4	24,0
Continua				

**Tabela D.1 – ELM: resultados da amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
NovoCD10sat	6,8	14,8	11,0	20,1
	11,4	20,2	11,4	24,5
	17,6	24,2	12,7	28,7
	25,8	27,1	15,2	32,5
NovoCD8sat	0,7	13,9	12,0	15,5
	4,9	15,2	11,0	20,4
	11,2	17,5	11,4	25,1
	14,8	19,2	13,4	29,7
NovoCU10sat	0,6	28,6	11,0	25,5
	0,0	40,8	10,0	33,9
	0,0	50,2	8,4	40,9
	0,0	57,7	6,9	46,5
4anosCD10sat	6,0	14,3	5,1	18,5
	8,9	21,6	7,9	24,6
	8,2	27,7	11,9	30,5
	4,6	34,9	17,7	36,0
4anosCD14sat	9,6	14,3	7,4	15,0
	19,8	28,2	10,0	21,9
	26,0	33,9	13,6	28,4
	22,9	39,8	18,6	34,4
4anosCU10sat	13,4	28,8	6,1	31,7
	9,4	42,9	7,7	43,9
	0,0	58,5	8,3	54,2
	0,0	66,0	8,7	61,5
SF	25,0	24,8	31,2	17,7
S5	11,2	45,8	3,1	45,9
S14	12,2	34,1	8,0	42,6
S21	16,1	30,8	14,5	32,0
Continua				

Tabela D.1 – ELM: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
1	5,0	17,8	4,9	16,1
	12,3	22,2	4,7	21,8
	18,8	26,3	6,4	27,5
	27,5	29,4	10,3	33,0
	36,0	33,7	16,8	38,3
2	4,2	16,3	-2,9	14,4
	5,1	24,7	-3,7	20,3
	2,0	31,8	-0,9	26,1
	0,0	37,6	5,8	31,6
	0,0	42,4	16,6	36,6
1	38,0	16,0	12,6	24,5
1	34,0	23,0	14,7	22,3
1	18,0	11,0	21,1	18,7
1	42,0	13,0	24,0	17,8
1	5,0	11,0	12,2	16,6
	3,5	24,0	16,2	21,6
	11,0	30,0	22,5	26,7
	25,0	33,0	31,5	31,5
	45,0	39,0	43,2	36,1
	44,0	43,0	58,0	40,2
	63,0	45,0	75,8	43,7
RS1	11,2	26,7	36,4	16,6
	20,5	26,7	27,0	25,0
	5,3	20,6	21,0	27,1
	2,4	19,0	6,3	23,9
Continua				

Tabela D.1 – ELM: resultados da amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
RS2	22,3	29,0	24,8	27,1
	30,7	24,9	19,9	27,5
	13,7	23,2	7,3	25,0
	9,1	21,8	4,5	23,5
RS2	24,5	33,1	20,3	29,3
	34,0	29,4	15,6	28,1
	13,1	26,4	4,1	23,7
	12,9	23,7	17,5	25,1
LW4	21,6	9,6	28,2	10,6
	32,0	15,0	44,6	20,6
LW3	23,0	18,0	17,2	18,4
	32,0	26,0	35,3	26,3
LW1	0,0	29,5	16,3	24,8
1	12,0	25,0	15,2	36,1
1	19,0	16,4	29,4	13,0
	22,0	26,4	37,7	19,2
2	18,0	18,4	16,7	18,5
	24,0	28,6	35,6	26,3
1	45,0	14,0	27,7	11,4

**ANEXO E – LS-SVR: RESULTADOS DAS ESTIMATIVAS DA AMOSTRA  
TOTAL DOS DADOS**

Tabela E.1 – LSSVR: resultados observados e preditos para amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
AM2-A3I2	4,2	5,0	6,9	7,1
	12,9	16,7	14,7	17,7
	17,6	24,2	19,0	24,4
	21,2	30,9	22,2	30,5
	26,6	36,8	27,1	35,8
	39,0	41,5	38,3	40,1
	59,5	45,0	56,9	43,3
	87,9	48,1	82,6	46,1
AM2-A4I2	0,0	6,8	3,1	8,7
	0,0	19,7	3,1	20,4
	1,8	27,1	4,7	27,1
	9,4	31,9	11,6	31,4
	21,4	36,1	22,4	35,2
	39,9	39,9	39,1	38,6
	71,9	41,6	68,1	40,2
	105,8	43,9	98,8	42,3
AM2-ABI2	5,6	0,0	8,1	2,6
	10,4	14,2	12,5	15,4
	21,0	20,9	22,1	21,5
	23,8	30,1	24,6	29,8
	27,2	38,4	27,7	37,3
	30,1	46,2	30,3	44,3
Continua				

Tabela E.1 – LSSVR: resultados para amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
AM3-ABI2	2,9	8,5	5,7	10,2
	11,4	16,8	13,4	17,7
	12,6	27,8	14,5	27,7
	13,8	36,2	15,5	35,3
	13,1	43,0	14,9	41,4
	11,8	50,2	13,7	48,0
Matriz C	0,0	12,9	3,1	14,2
	4,0	22,9	6,7	23,3
	8,8	29,1	11,0	28,9
	14,6	32,3	16,3	31,8
	21,6	33,4	22,6	32,8
	31,9	33,1	31,9	32,5
Matriz A	0,0	12,9	3,1	14,2
	4,0	22,9	6,7	23,3
	8,8	29,1	11,0	28,9
	14,6	32,3	16,3	31,8
	21,6	33,4	22,6	32,8
	31,9	33,1	31,9	32,5
T2A12nat	8,6	18,0	10,8	18,8
	20,0	22,0	21,1	22,5
	30,2	25,7	30,4	25,8
	39,2	29,0	38,5	28,8
	54,2	31,0	52,1	30,6
	71,5	33,3	67,7	32,7
	111,8	33,0	104,2	32,4
Continua				

**Tabela E.1 – LSSVR: resultados para amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T2A12sat	15,0	14,5	16,6	15,7
	31,4	17,0	31,5	17,9
	47,1	19,5	45,7	20,2
	60,7	23,0	58,0	23,4
	73,0	27,0	69,1	27,0
	85,6	30,6	80,5	30,2
	97,4	34,7	91,2	33,9
T2A10nat	4,7	16,7	7,3	17,7
	19,5	19,0	20,7	19,7
	37,9	21,0	37,3	21,5
	60,2	22,0	57,5	22,5
	101,6	21,7	95,0	22,2
	115,4	24,0	107,4	24,3
T2A14nat	14,5	17,0	16,2	17,9
	33,3	20,0	33,2	20,6
	50,9	22,2	49,1	22,6
	74,9	24,3	70,8	24,5
	91,5	27,3	85,8	27,2
	121,7	29,0	113,1	28,8
	140,6	32,0	130,2	31,5
T2A12CU <sub>nat</sub>	37,0	20,5	36,5	21,1
	33,4	42,6	33,3	41,1
	48,5	53,0	46,9	50,5
T2A12CU <sub>sat</sub>	14,9	41,3	16,5	39,9
	49,7	48,5	48,0	46,4
	65,3	56,3	62,1	53,5
Continua				



**Tabela E.1 – LSSVR: resultados para amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T1B12nat	0,0	18,7	3,1	19,5
	9,9	23,0	12,0	23,4
	21,5	26,0	22,5	26,1
	37,6	28,4	37,1	28,2
	50,6	31,6	48,8	31,1
	68,1	33,8	64,7	33,1
	100,9	35,0	94,3	34,2
T1B12sat	5,5	17,0	8,0	17,9
	26,0	20,0	26,6	20,6
	44,5	22,5	43,3	22,9
	71,2	24,6	67,5	24,8
	99,5	26,5	93,1	26,5
	150,2	26,0	138,9	26,1
	196,0	26,6	180,4	26,6
T1B12CUsat	0,0	29,3	3,1	29,1
	0,0	44,8	3,1	43,1
	0,0	56,8	3,1	53,9
T2B12nat	22,1	8,7	22,8	10,3
	35,7	10,0	35,1	11,5
	38,9	13,0	38,1	14,2
	47,1	14,8	45,6	15,9
	73,4	13,9	69,6	15,1
	116,4	11,6	108,7	13,0
	145,8	11,3	135,5	12,7
Continua				

**Tabela E.1 – LSSVR: resultados para amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
T2B12sat	8,7	14,0	10,8	15,0
	12,9	16,6	14,8	17,3
	22,7	17,7	23,7	18,4
	33,3	19,0	33,4	19,6
	47,2	19,5	46,2	20,0
	71,9	18,6	69,1	19,2
	89,9	18,4	85,7	19,0
T2B12CUsat	0,0	29,5	3,1	29,2
	0,0	44,1	3,1	42,4
	0,0	53,1	3,1	50,6
Matriz T2a	20,0	22,0	21,1	22,5
	33,1	27,3	33,0	27,2
Matriz T1b	36,5	21,3	36,1	21,8
	54,9	27,0	52,7	27,0
Matriz T2b	37,0	19,7	36,5	20,4
	44,1	25,8	42,9	25,9
T2a40CDnat	33,8	18,5	33,6	19,3
	73,8	22,0	69,8	22,5
	103,0	22,5	96,2	22,9
T2a40CDsat	18,3	18,3	19,6	19,1
	54,4	20,8	52,3	21,4
	78,7	21,3	74,2	21,8
T1b40CDsat	20,4	16,3	21,5	17,3
	47,3	20,8	45,9	21,4
	59,7	23,5	57,1	23,8
T2b40CDsat	23,3	12,3	24,1	13,6
	26,9	17,0	27,4	17,9
	30,7	19,0	30,9	19,7
Continua				

**Tabela E.1 – LSSVR: resultados para amostra total dos dados**

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
NovoCD10sat	6,8	14,8	9,2	15,9
	11,4	20,2	13,4	20,8
	17,6	24,2	19,0	24,4
	25,8	27,1	26,4	27,1
NovoCD8sat	0,7	13,9	3,7	15,1
	4,9	15,2	7,5	16,3
	11,2	17,5	13,2	18,4
	14,8	19,2	16,4	19,9
NovoCU10sat	0,6	28,6	3,6	28,5
	0,0	40,8	3,1	39,5
	0,0	50,2	3,1	48,0
	0,0	57,7	3,1	54,8
4anosCD10sat	6,0	14,3	8,5	15,5
	8,9	21,6	11,1	22,1
	8,2	27,7	10,5	27,6
	4,6	34,9	7,2	34,1
4anosCD14sat	9,6	14,3	11,7	15,5
	19,8	28,2	21,0	28,1
	26,0	33,9	26,6	33,2
	22,9	39,8	23,8	38,6
4anosCU10sat	13,4	28,8	15,1	28,6
	9,4	42,9	11,6	41,4
	0,0	58,5	3,1	55,5
	0,0	66,0	3,1	62,3
SF	25,0	24,8	25,7	25,0
S5	11,2	45,8	13,2	44,0
S14	12,2	34,1	14,1	33,4
S21	16,1	30,8	17,6	30,4
Continua				

Tabela E.1 – LSSVR: resultados para amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
1	5,0	17,8	7,6	18,6
	12,3	22,2	14,2	22,6
	18,8	26,3	20,0	26,3
	27,5	29,4	27,9	29,1
	36,0	33,7	35,6	33,1
2	4,2	16,3	6,8	17,3
	5,1	24,7	7,7	24,9
	2,0	31,8	4,9	31,3
	0,0	37,6	3,1	36,6
	0,0	42,4	3,1	40,9
1	38,0	16,0	37,4	17,0
1	34,0	23,0	33,8	23,4
1	18,0	11,0	19,3	12,5
1	42,0	13,0	41,0	14,3
1	5,0	11,0	7,6	12,5
	3,5	24,0	6,2	24,3
	11,0	30,0	13,0	29,7
	25,0	33,0	25,7	32,4
	45,0	39,0	43,8	37,8
	44,0	43,0	42,9	41,4
	63,0	45,0	60,0	43,3
RS1	11,2	26,7	13,2	26,7
	20,5	26,7	21,6	26,7
	5,3	20,6	7,8	21,2
	2,4	19,0	5,2	19,7
Continua				

Tabela E.1 – LSSVR: resultados para amostra total dos dados

Nº do ensaio ou designação da amostra	$c'$ (KPa)	$\phi'$ (°)	$c'_{predito}$ (KPa)	$\phi'_{predito}$ (°)
RS2	22,3	29,0	23,2	28,8
	30,7	24,9	30,8	25,1
	13,7	23,2	15,4	23,5
	9,1	21,8	11,3	22,3
RS2	24,5	33,1	25,2	32,5
	34,0	29,4	33,8	29,1
	13,1	26,4	14,9	26,4
	12,9	23,7	14,7	24,0
LW4	21,6	9,6	22,6	11,2
	32,0	15,0	32,0	16,1
LW3	23,0	18,0	23,9	18,8
	32,0	26,0	32,0	26,1
LW1	0,0	29,5	3,1	29,2
1	12,0	25,0	13,9	25,2
1	19,0	16,4	20,2	17,4
	22,0	26,4	23,0	26,4
2	18,0	18,4	19,3	19,2
	24,0	28,6	24,8	28,4
1	45,0	14,0	43,8	15,2

ANEXO F – RESULTADO DO ATERRO DE SANTO TIRSO PARA A REDE NEURAL MLP

Tabela F.1 – MLP: Resultados do aterro de Santo Tirso

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM1	39,5	45,7	14,8	0,2	1,0	5,6	5	100,0	5,78	23,49
							10		6,88	29,48
							15		8,60	34,78
							20		11,28	39,44
AM1 – A3I <sub>2</sub>	18,2	61,8	13,9	1,1	0,8	5,5	5	100,0	6,75	24,97
							10		8,40	31,66
							15		10,97	37,55
							20		14,94	42,65
AM2 – A3I <sub>2</sub>	25,2	57,4	7,4	1,9	1,1	5,8	5	100,0	6,74	16,39
							10		8,38	22,08
							15		10,94	27,19
							20		14,90	31,79
Continua										

**Tabela F.1 – MLP: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM3 – A3I <sub>2</sub>	17,1	62,2	5,7	2,4	1,1	6,4	5	100,0	7,29	17,34
							10		9,24	23,22
							15		12,28	28,47
							20		16,96	33,17
AM1 – A4I <sub>2</sub>	18,7	57,9	6,7	2,2	1,0	4,4	5	100,0	6,79	13,41
							10		8,47	19,05
							15		11,08	24,13
							20		15,11	28,72
AM2 – A4I <sub>2</sub>	16,6	63,1	6,3	4,0	1,4	5,2	5	100,0	7,49	16,24
							10		9,55	22,52
							15		12,76	28,13
							20		17,68	33,12
AM3 – A4I <sub>2</sub>	16,6	63,1	6,3	5,4	0,7	7,5	5	100,0	8,04	23,59
							10		10,41	29,64
							15		14,08	34,97
							20		19,70	39,65
Continua										

**Tabela F.1 – MLP: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM1 – B1P <sub>1</sub>	28,8	58,0	4,9	2,9	0,6	5,7	5	100,0	6,88	11,64
							10		8,60	16,40
							15		11,29	20,76
							20		15,44	24,80
AM2 – B1P <sub>1</sub>	44,6	42,3	6,7	3,4	1,1	5,4	5	100,0	6,06	11,86
							10		7,32	16,58
							15		9,29	20,91
							20		12,35	24,93
AM1-B2P	23,6	64,9	6,3	3,1	0,6	7,2	5	100,0	7,47	18,91
							10		9,51	24,44
							15		12,70	29,39
							20		17,60	33,84
AM2-B2P	19,3	67,6	6,3	3,7	1,2	5,3	5	100,0	7,59	14,90
							10		9,70	20,85
							15		12,99	26,19
							20		18,05	30,97
Continua										



**Tabela F.1 – MLP: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM1 – B1I <sub>2</sub>	37,4	43,2	5,0	5,5	0,2	7,4	5	100,0	6,67	17,68
							10		8,28	22,38
							15		10,78	26,68
							20		14,66	30,65
AM2 – B1I <sub>2</sub>	18,6	58,3	4,3	6,0	0,7	7,8	5	100,0	7,95	22,20
							10		10,26	27,97
							15		13,86	33,09
							20		19,37	37,63
AM3 – B1I <sub>2</sub>	33,3	44,6	5,1	6,0	0,7	7,0	5	100,0	6,83	18,64
							10		8,53	23,80
							15		11,17	28,47
							20		15,25	32,70
AM1 – B1P <sub>2</sub>	37,7	42,6	4,8	5,5	0,5	6,9	5	100,0	6,61	16,20
							10		8,17	20,95
							15		10,62	25,30
							20		14,41	29,32
Continua										

**Tabela F.1 – MLP: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM2 – B1P <sub>2</sub>	30,7	51,0	3,6	6,0	0,4	10,0	5	100,0	7,56	24,81
							10		9,66	29,98
							15		12,92	34,60
							20		17,94	38,73
AM3 – B1P <sub>2</sub>	20,8	47,7	7,5	6,0	0,3	10,6	5	100,0	7,60	34,99
							10		9,73	40,75
							15		13,03	45,72
							20		18,10	49,96
AM1-C1P	41,6	22,4	24,7	5,9	0,2	8,5	5	100,0	5,73	40,56
							10		6,80	46,72
							15		8,47	52,13
							20		11,08	56,73
AM2-C1P	46,5	27,3	15,0	9,1	0,3	9,2	5	100,0	6,38	39,08
							10		7,81	44,69
							15		10,05	49,48
							20		13,53	53,52
Continua										

**Tabela F.1 – MLP: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM3-C1P	33,1	46,3	9,4	8,1	0,3	10,9	5	100,0	7,61	36,79
							10		9,74	42,42
							15		13,06	47,25
							20		18,14	51,36
AM1 – C2I <sub>2</sub>	31,1	31,3	9,1	10,0	0,4	9,3	5	100,0	7,09	35,90
							10		8,93	41,61
							15		11,79	46,52
							20		16,21	50,71
AM2 – C2I <sub>2</sub>	37,8	30,8	12,5	9,4	0,5	9,0	5	100,0	6,73	37,06
							10		8,36	42,90
							15		10,92	47,91
							20		14,87	52,15

ANEXO G – RESULTADO DO ATERRO DE SANTO TIRSO PARA A REDE NEURAL ELM

Tabela G.1 – ELM: Resultados do aterro de Santo Tirso

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM1	39,5	45,7	14,8	0,2	1,0	5,6	5	100,0	0,08	31,27
							10		-1,40	38,01
							15		-1,07	44,52
							20		1,53	50,65
AM1 – A3I <sub>2</sub>	18,2	61,8	13,9	1,1	0,8	5,5	5	100,0	-7,98	37,59
							10		-3,65	43,51
							15		1,56	49,27
							20		8,03	54,71
AM2 – A3I <sub>2</sub>	25,2	57,4	7,4	1,9	1,1	5,8	5	100,0	-3,36	35,10
							10		-0,92	41,54
							15		3,29	47,86
							20		9,73	53,92
Continua										

**Tabela G.1 – ELM: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM3 – A3I <sub>2</sub>	17,1	62,2	5,7	2,4	1,1	6,4	5	100,0	-3,84	36,76
							10		0,55	43,08
							15		6,41	49,30
							20		14,19	55,24
AM1 – A4I <sub>2</sub>	18,7	57,9	6,7	2,2	1,0	4,4	5	100,0	-5,31	33,89
							10		-2,05	39,95
							15		2,97	45,97
							20		10,18	51,81
AM2 – A4I <sub>2</sub>	16,6	63,1	6,3	4,0	1,4	5,2	5	100,0	-4,53	32,46
							10		0,25	38,32
							15		6,69	44,15
							20		15,19	49,79
AM3 – A4I <sub>2</sub>	16,6	63,1	6,3	5,4	0,7	7,5	5	100,0	1,01	34,02
							10		5,84	41,88
							15		11,82	49,51
							20		19,36	56,74
Continua										

**Tabela G.1 – ELM: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM1 – B1P <sub>1</sub>	28,8	58,0	4,9	2,9	0,6	5,7	5	100,0	-0,37	37,44
							10		2,02	44,47
							15		6,40	51,35
							20		13,24	57,92
AM2 – B1P <sub>1</sub>	44,6	42,3	6,7	3,4	1,1	5,4	5	100,0	-4,02	26,12
							10		-5,10	33,31
							15		-3,22	40,33
							20		2,05	47,02
AM1-B2P	23,6	64,9	6,3	3,1	0,6	7,2	5	100,0	0,37	38,15
							10		4,45	45,59
							15		9,88	52,83
							20		17,10	59,70
AM2-B2P	19,3	67,6	6,3	3,7	1,2	5,3	5	100,0	-4,61	34,39
							10		0,69	40,30
							15		7,56	46,16
							20		16,44	51,83
Continua										

**Tabela G.1 – ELM: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM1 – B1I <sub>2</sub>	37,4	43,2	5,0	5,5	0,2	7,4	5	100,0	7,99	35,84
							10		7,78	44,60
							15		9,85	53,02
							20		14,68	60,92
AM2 – B1I <sub>2</sub>	18,6	58,3	4,3	6,0	0,7	7,8	5	100,0	3,81	33,99
							10		7,61	42,15
							15		12,86	50,05
							20		20,01	57,53
AM3 – B1I <sub>2</sub>	33,3	44,6	5,1	6,0	0,7	7,0	5	100,0	3,70	35,21
							10		4,26	43,13
							15		7,11	50,76
							20		12,75	57,93
AM1 – B1P <sub>2</sub>	37,7	42,6	4,8	5,5	0,5	6,9	5	100,0	4,15	35,07
							10		4,10	43,16
							15		6,53	50,94
							20		11,95	58,25
Continua										

**Tabela G.1 – ELM: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM2 – B1P <sub>2</sub>	30,7	51,0	3,6	6,0	0,4	10,0	5	100,0	13,24	30,86
							10		14,19	41,00
							15		16,80	50,78
							20		21,58	59,99
AM3 – B1P <sub>2</sub>	20,8	47,7	7,5	6,0	0,3	10,6	5	100,0	14,12	26,70
							10		14,86	37,36
							15		16,50	47,58
							20		19,50	57,19
AM1-C1P	41,6	22,4	24,7	5,9	0,2	8,5	5	100,0	20,50	33,98
							10		16,04	41,26
							15		12,37	47,87
							20		9,98	53,65
AM2-C1P	46,5	27,3	15,0	9,1	0,3	9,2	5	100,0	14,75	33,18
							10		11,42	42,20
							15		9,89	50,62
							20		10,67	58,24
Continua										



**Tabela G.1 – ELM: Resultados do aterro de Santo Tirso**

Designação da Amostra	Composição			T (anos)	$\omega$ (%)	$\gamma_d$ (KN/m <sup>3</sup> )	$\varepsilon_a$ (%)	$\sigma'_3$ máxima (KPa)	$c'$ (KPa)	$\phi'$ (°)
	A (%)	B (%)	C (%)							
AM3-C1P	33,1	46,3	9,4	8,1	0,3	10,9	5	100,0	17,68	23,59
							10		17,04	34,83
							15		17,57	45,59
							20		19,76	55,68
AM1 – C2I <sub>2</sub>	31,1	31,3	9,1	10,0	0,4	9,3	5	100,0	13,65	30,29
							10		12,17	40,11
							15		12,41	49,41
							20		14,87	58,01
AM2 – C2I <sub>2</sub>	37,8	30,8	12,5	9,4	0,5	9,0	5	100,0	12,17	33,16
							10		10,09	42,11
							15		9,76	50,50
							20		11,66	58,17