




Tecnologias de solos não saturados e seu potencial de aplicação à pavimentação

Gilson de F. N. Gitirana Jr., Ph.D.
Professor Titular, Universidade Federal de Goiás

Laboratório de Geotecnia e Centro de Estudos Hidrológicos e Geotécnicos da UFG



Laboratório de Geotecnia e Centro de Estudos Hidrológicos e Geotécnicos da UFG



Salão de modelos físicos

Recursos para
investigação de campo




Laboratório de Geotecnia e Centro de Estudos Hidrológicos e Geotécnicos da UFG



Laboratório de ensaios mecânicos

Lab. de ensaios de erosão e infiltrabilidade



Laboratório de Geotecnia e Centro de Estudos Hidrológicos e Geotécnicos da UFG



Laboratório de caracterização



Laboratório de asfalto

Laboratório de Geotecnia e Centro de Estudos Hidrológicos e Geotécnicos da UFG



Laboratório de solos não saturados

Laboratório de Geotecnia e Centro de Estudos Hidrológicos e Geotécnicos da UFG




Prof. Gilson Gitirana



Profa. Lilian Rezende



Prof. Raviel Basso



Prof. Fernando Marinho (USP)



Jeferson
Freitas (MSc)



David
Cavalcante
(MSc)



Roberto Alves
(DSc, PhD)



Sávio Pereira
(MSc)



Karolayne de
Melo (MSc)



Lara de Lima
(MSc)



Minilik Damtie
(MSc)



Jorge Filemom
(Mestrando)

Ação do clima nos pavimentos

Ação do clima nos pavimentos



1. Introdução
2. Danos causados pela água
3. Fundamentos da drenagem dos pavimentos
4. Estimativa de influxos e efluxos
5. Critérios para projeto de drenos subterrâneos
6. Sistemas típicos de drenagem subterrânea
7. Proteção dos sistemas de drenagem
8. Economia dos pavimentos drenados e não drenados
9. Desempenho dos materiais de graduação aberta
10. Redução da aquaplanagem com pavimentos e capas porosas

DRENAGEM DOS PAVIMENTOS DE RODOVIAS E AERÓDROMOS

HARRY R. CEDERGREN



MT-DNER-INSTITUTO DE PESQUISAS RODOVIÁRIAS
LIVROS TÉCNICOS E CIENTÍFICOS EDITORA S.A.

Cedergren (1980)


Ação do clima nos pavimentos

► Subleito



- Acostamento
- Trincas/falha de drenagem
- Evaporação como efeito positivo
- Oscilação do lençol
- Migração de vapor
- Congelamento

► Estrutura do pavimento

- Intemperização
- Resistência à derrapagem
- Migração de sais





Sub-base



Medina e Motta (2015)

Clima em Goiânia - GO



Precipitação anual média: ~1500 mm

Evaporação anual média: ~1800 mm

Fonte: INMET, Faculdade de Agronomia, UFG

Clima em Goiânia - GO




Campo experimental de Furnas em Aparecida de Goiânia – GO

Silva Jr. (2011)

Flutuação de NA e umidade

**Solo residual de
micaxisto de Goiânia**


Fonte: Silva Jr & Gitirana Jr (2014)



Flutuação de NA e sucção



**Solo residual de
micaxisto de Goiânia**

Fonte: Silva Jr & Gitirana Jr (2014)



O projeto de pavimentos e alguns dos parâmetros necessários

Metodologia mecanística-empírica de projeto de pavimentos flexíveis



Huang (2004)

MeDiNa



a (2015)

Medina & Motta (2015) modificado por Farias (2026)

MeDiNa

Camada	Propriedades	Parâmetros	Norma	Quantidade de corpos de prova
Camadas granulares e subleito	Deformabilidade elástica	Coeficiente de Poisson (ν)	(arbitrado, ver Tabela 1)	-
		k_1, k_2, k_3 , e k_4 ou MR = cte	DNIT 134/2018-ME	3
	Deformação permanente	ψ_1, ψ_2, ψ_3 , e ψ_4	DNIT 179/2018-IE	Preferencialmente 9, no mínimo 6
Misturas asfálticas	Deformabilidade elástica	Coeficiente de Poisson (ν)	(arbitrado, ver Tabela 1)	-
		MR	DNIT 135/2018-ME	3
	Fadiga	RT	DNIT 136/2018-ME	3
		k_1 e k_2	DNIT 183/2018-ME	12

IPR (2025)

Módulo de Resiliência: efeito das variáveis de estado de tensão

Tensões totais

$$\sigma_d = \sigma_1 - \sigma_3$$

$$\tau_{oct} = (\sqrt{2}/3)\sigma_d$$

$$\theta_b = \sigma_1 + 2\sigma_3 = 3\sigma_3 + \sigma_d$$

$$\theta_m = 3\sigma_3 = \theta_b - \sigma_d$$

Legenda

σ_3 = tensão principal menor (confinante)

σ_1 = tensão principal maior (axial)

σ_d = tensão desvio

τ_{oct} = tensão cisalhante octaédrica

θ_b = tensão volumétrica

θ_m = tensão volumétrica mínima





Imagem: owntec.com.br

Módulo de Resiliência: efeito das variáveis de estado de tensão

Reference	Variables	Equation
Hicks (1970)	σ_3	$M_R = k_1 \sigma_3^{k_2}$
Hicks (1970)	θ_b	$M_R = k_1 \theta_b^{k_2}$
Svenson (1980)	σ_d	$M_R = k_1 \sigma_d^{k_2}$
Moossazadeh & Witczak (1981)	σ_d	$M_R = k_1 \left(\frac{\sigma_d}{p_a} \right)^{k_2}$
Macedo (1996)	σ_3, σ_d	$M_R = k_1 \sigma_3^{k_2} \sigma_d^{k_3}$
Uzan (1985)	θ_b, σ_d	$M_R = k_1 p_a \left(\frac{\theta_b}{p_a} \right)^{k_2} \left(\frac{\sigma_d}{p_a} \right)^{k_3}$
Uzan (1985)	θ_b, τ_{oct}	$M_R = k_1 p_a \left(\frac{\theta_b}{p_a} \right)^{k_2} \left(\frac{\tau_{oct}}{p_a} \right)^{k_3}$
MEPDG (2008)	θ_b, τ_{oct}	$M_R = k_1 p_a \left(\frac{\theta_b}{p_a} \right)^{k_2} \left(1 + \frac{\tau_{oct}}{p_a} \right)^{k_3}$
Manual MeDiNa (DNIT, 2020)	$\sigma_3, \sigma_d, \theta_b$	$M_R = k_1 \sigma_3^{k_2} \sigma_d^{k_3} \theta_b^{k_4}$

Módulo de Resiliência: efeito das condições não saturadas



Properties	Lateritic soil (SUB1)			Non-lateritic soil (SUB2)		
	Target	Mean	CV (%)	Target	Mean	CV (%)
w (%)	17.5	16.9	1.10	13.4	12.8	1.57
ρ _d (g/cm ³)	1.720	1.700	0.13	1.800	1.770	0.12
e (-)	0.570	0.585	0.35	0.500	0.523	0.35
S (%)	82.9	78.0	1.24	72.1	58.9	1.60

Freitas, Ribeiro & Gitirana Jr. (2020)

Módulo de Resiliência: efeito das condições não saturadas

Tensões totais

$$\sigma_d = \sigma_1 - \sigma_3$$

$$\tau_{oct} = (\sqrt{2}/3)\sigma_d$$

$$\theta_b = \sigma_1 + 2\sigma_3 = 3\sigma_3 + \sigma_d$$

$$\theta_m = 3\sigma_3 = \theta_b - \sigma_d$$

Sucção

$$\psi = \psi_m + \pi$$

$$\psi_m = u_a - u_w$$

Quantidade de água

$$w = m_w/m_s$$

$$\theta_w = V_w/V$$

$$S_r = V_w/V_v$$

$$dw = w - w_{opt}$$

Legenda

σ_3 = tensão principal menor (confinante)

σ_1 = tensão principal maior (axial)

σ_d = tensão desvio

τ_{oct} = tensão cisalhante octaédrica

θ_b = tensão volumétrica

θ_m = tensão volumétrica mínima

ψ = sucção total

ψ_m = sucção matricial

w = umidade gravimétrica

θ_w = umidade volumétrica

S_r = grau de saturação

dw = desvio em relação à umidade ótima

Módulo de Resiliência: efeito das condições não saturadas

Reference	Variables	Equation
Ceratti et al. (2004)	ψ	$M_R = k_1 + k_2\psi$
Parreira & Gonçalves (2000)	σ_d, ψ	$M_R = k_1\sigma_d^{k_2}\psi^{k_3}$
Doucet & Doré (2004)	θ_b, ψ	$M_R = k_1\theta_b - k_2\psi + k_3$
Oloo & Fredlund (1998)	θ_b, ψ	$M_R = k_2 - k_3 \theta_b - k_1 + k_2\psi$
Oh et al. (2012)	θ_b, τ_{oct} θ_w, ψ	$M_R = k_1p_a \left(\frac{\theta_b + 3k_4\psi\theta_w}{p_a} \right)^{k_2} \left(1 + \frac{\tau_{oct}}{p_a} \right)^{k_3}$
Heath et al. (2004)	θ_b, σ_d ψ	$M_R = k_1p_a \left(\frac{\theta_b + k_4\psi}{p_a} \right)^{k_2} \left(\frac{\sigma_d}{p_a} \right)^{k_3}$
Liang et al. (2008)	θ_b, τ_{oct} ψ	$M_R = k_1p_a \left(\frac{\theta_b + k_4\psi}{p_a} \right)^{k_2} \left(1 + \frac{\tau_{oct}}{p_a} \right)^{k_3}$

Módulo de Resiliência: efeito das condições não saturadas

Reference	Variables	Equation
Zhang et al. (2018)	θ_m, τ_{oct} ψ	$M_R = k_1 p_a \left[\ln \left(\frac{\psi}{p_a} + e \right) + k_2 \right] \left(\frac{\theta_m}{p_a} \right)^{k_3} \left(\frac{\tau_{oct}}{p_a} + 1 \right)^{k_4}$
Santos (2020)	Δ, ψ_m	$M_R = k_1 p_a \left(\frac{\Delta}{p_a} \right)^{k_2} \left(\frac{\psi_m}{p_a} + k_3 \right)^{k_4}$
Pérez-García et al. (2016)	σ_3, σ_d w	$M_R = e^{k_1 - k_2(w - w_{opt})} \left(\frac{\sigma_d}{\sigma_3} \right)^{k_3}$
Freitas et al. (2020)	Δ, w, ψ_m	$M_R = e^{k_1 - k_2(w - w_{opt})} \psi_m^{k_3} \Delta^{k_4}$
Kern (2022)	σ_3, σ_d w, ψ_m	$M_R = e^{k_1 - k_2(w - w_{opt})} \psi_m^{k_3} \sigma_3^{k_4} \sigma_d^{k_5}$

Aplicação de tecnologias de solos não saturados à engenharia de pavimentos: laboratório e campo

Áreas de aplicação

▶ Perguntas

- ▶ Qual a distribuição espacial e temporal de umidade e sucção no pavimento?
- ▶ Qual o efeito da variação de sucção e umidade, nos parâmetros mecânicos?

▶ Investigação de laboratório

- ▶ Imposição e monitoramento de sucção
- ▶ Propriedades mecânicas e hidráulicas

▶ Investigação de campo


- ▶ Monitoramento de sucção e umidade
- ▶ Acoplamento com hidrologia

▶ Modelagem

- ▶ Modelos constitutivos
- ▶ Modelos de pedo-transferência

Áreas de aplicação

► Múltiplas escalas, múltiplos climas





Fonte: IPR
(PRO-MeDiNa)

A centralidade da curva de retenção

van Genuchten (1980)



$$k^w = \left[\frac{1 - [\alpha(u_a - u_w)]^{n-1} \{1 + [\alpha(u_a - u_w)]^n\}^{-m}}{\{1 + [\alpha(u_a - u_w)]^n\}^{m/2}} \right]^2$$




A centralidade da curva de retenção

Fredlund et al. (1996)

$$\tan \phi^b = \Theta^{\kappa} \tan \phi'$$



A centralidade da curva de retenção



Métodos de aplicação de sucção

Vapor transfer
(control of relative humidity or total suction, ψ)

Relative humidity control with non-volatile solutes
(salt/base solutions)
Recommended range:

ψ 4 MPa to 400 MPa
Types of aqueous solutions:
- partially saturated solutions
- saturated solutions

Relative humidity control with volatile solutes
(acid solutions)
Recommended range for H_2SO_4 aqueous solution:
 $\psi = 20$ MPa to 400 MPa

Relative humidity application:

Pure diffusion
(> 3 weeks for equalization)

Forced convection transport through air
(< 3 weeks for equalization)

Vapor transport along the boundaries of the sample
(suitable for nearly saturated states blocking air flow through the sample)

Vapor transport through the sample
(more efficient, but limited to the continuity of air: $S_r < 0.90$)

Predominant liquid phase transfer through a membrane permeable to dissolved salts
(control of matrix suction, s)

Osmotic technique with PEG 20000 or 35000
(< 2 weeks for equalization)
Range: s 0.1 MPa to 1.5 MPa

Axis translation
(< 2 weeks for equalization)
Range: s 0.01 MPa to 1.5 MPa (HAEV ceramic disc) or to 7 MPa (cellulose acetate membrane)

Symmetric membranes
(cellulose acetate: Viskase, Spectrum 4, Spectrum 5)

Asymmetric membranes
(polyether sulphone)

most suitable technique for nearly saturated states $S_r > 0.95$
(for example in shrinkage paths)

Air overpressure
(constant air pressure)

not suitable for nearly saturated states $S_r > 0.95$.
If applied in such states, then air overpressure technique should be used

Water subpressure
(constant water pressure)

Interface:


cellulose acetate membrane:
higher suction ranges, lower equilization periods, less durables, higher coeff. of diffusion of air, higher compressibility upon loading, more suitable for drying paths)

HAEV ceramic disc:
suitable for both drying and wetting paths


Romero (2001)

Curva característica: placa de pressão

- ▶ **Agronomia**
 - ▶ Avanços importantes
 - ▶ Tensões totais raramente consideradas
- ▶ **Tipos de equipamentos**
 - ▶ Corpos de prova individuais ou múltiplos
 - ▶ Sucção total e matricial
- ▶ **Sucção matricial**
 - ▶ Translação de eixos ou tração direta na água
 - ▶ 1500 kPa é o limite
 - ▶ Secagem a partir de saturação é mais comum
- ▶ **Sucção total**
 - ▶ Umidade relativa do ar controlada
- ▶ **ASTM D6836-02**




Placa de pressão da UoS



Dessecador

Curva característica: placa de pressão



(a)



5-bar ceramic plate extractor (SoilMoisture Equipment Corporation, Santa Barbara, CA)



(b)

Tempe Cell (SoilMoisture Equipment Corporation, Santa Barbara, CA)

Curva característica: placa de pressão




Volumetric pressure plate extractor
(SoilMoisture Equipment
Corporation, Santa Barbara, CA)



Pressure plate membrane extractor
(SoilMoisture Equipment
Corporation, Santa Barbara, CA)

Curva característica: placa de pressão

- ▶ **Necessidades da geotecnia**
 - ▶ Corpos de prova individuais
 - ▶ Amostras indeformadas
 - ▶ Aplicação de tensões totais
 - ▶ Monitoramento de volume total
 - ▶ Secagem e molhagem
 - ▶ Facilidade de operação sob elevadas pressões
 - ▶ Atenção ao ar difuso





Placa de pressão K₀ de Barcelona
(CIMNE, Barcelona, Spain)

Curva característica: placa de pressão

▶ Placa de pressão da GCTS

- ▶ Secagem e molhagem
- ▶ Até 1500 kPa
- ▶ Cerâmicas de alto valor de entrada de ar facilmente removíveis
- ▶ Carregamento vertical
- ▶ Compensador de pressão
- ▶ Duas buretas
- ▶ Volume total
- ▶ Aquecedor



Sucção via determinação de umidade relativa do ar

- ▶ **Sucção total**
- ▶ **Fundamentos**
 - ▶ Equilíbrio termodinâmico entre o vapor do ar e potencial da água do poro do solo

$$\psi = -\frac{RT_K}{v_{w0}\omega_v} \ln\left(\frac{\bar{u}_v}{\bar{u}_{v0}}\right)$$


$$\psi = -135,053 \ln\left(\frac{\bar{u}_v}{\bar{u}_{v0}}\right)$$



Dessecador

Sucção via determinação de umidade relativa do ar

- ▶ **Potenciômetro de ponto de orvalho**
- ▶ **Gee et al. (1992)**
- ▶ **ASTM D 6836-02 (2008)**
- ▶ **Câmara fechada**
 - ▶ Ventoinha
 - ▶ Espelho que é resfriado
 - ▶ Célula fotoelétrica
 - ▶ Termômetro infravermelho
- ▶ **Porta amostras com 40 mm de diâmetro**



WP4 chilled-mirror Water Potential Meter
(Decagon Devices, Pullman, WA)

Método do papel filtro

- ▶ Ampla faixa de sucções
- ▶ Ensaio delicado
- ▶ Sem contato → sucção total
- ▶ Com contato → sucção matricial
- ▶ Princípios
 - ▶ Filter paper atuando como sensor
 - ▶ Método indireto
 - ▶ Curva de calibração
 - ▶ Equilíbrio via transferência de vapor ou de água líquida




Bulut (2001)

Sensores de sucção matricial baseados em dissipação de calor

- ▶ Não requer manutenção periódica
- ▶ Moisture Control System (1970)
 - ▶ Faixa entre 0 e 300 kPa
- ▶ Agwatronics → AGWA (1981) and AGWA II (1984) sensors
 - ▶ Novo bloco poroso
- ▶ GCTS (2000) → University of Saskatchewan design
 - ▶ Example of use: sensors working for over 10 years in a test field





Sensor da UFG (Mota et al., 2021)



FTC-100 suction sensor (GCTS)

Sensores de sucção matricial baseados em dissipação de calor



- ▶ Exemplo de monitoramento de pavimento
- ▶ Mais de 5 anos de monitoramento contínuo



Tan, Fredlund & Gitirana Jr. (2004)



Tensiômetros

- ▶ Medição direta de sucção matricial
- ▶ Sucção máxima delimitada pela cavitação
- ▶ Compartimento preenchido com água de-aerada transite tensão à um sensor de pressão
- ▶ Tempo de resposta relativamente curto




Tensiômetro de elevada capacidade do Imperial College (after Ridley, 1993)


Instrumentação de sucção em ensaios triaxiais utilizando tensiômetros




Instrumentação de sucção em ensaios triaxiais utilizando tensiômetros



Instrumentação de sucção em ensaios triaxiais utilizando tensiômetros



Lima, Ribeiro,
Gitirana Jr. (2026)



Módulo de Resiliência: efeito das condições não saturadas

Properties	Lateritic soil: Subgrade 1 (SUB1)		Non-lateritic soil: Subgrade 2 (SUB2)	
Particle size	without dispersant	with dispersant	without dispersant	with dispersant
Gravel (%)	4.1	4.1	8.9	8.9
Sand (%)	57.8	60.9	69.9	60.4
Silt (%)	38.0	8.8	21.2	30.7
Clay (%)	0.0	26.2	0.0	0.0
Index properties				
Specific gravity	2.700		2.660	
Liquid limit (%)	34		not determined	
Plastic limit (%)	18		not determined	
Plasticity index (%)	16		non-plastic	
Classification				
TRB	CL		SM	
USCS	A6		A4	
MCT	LG'		NS'	
Compaction and CBR (standard Proctor energy)				
w_{opt} (%)	17.5		13.4	
$\rho_d \text{ max}$ (g/cm ³)	1.720		1.800	
CBR (%)	18		5	
Swelling (%)	0.08		2.30	

Correlação em Módulo de Resiliência e variáveis de estado do solo



Variables	Pearson		Spearman	
	Lateritic (SUB1)	Non-lateritic (SUB2)	Lateritic (SUB1)	Non-lateritic (SUB2)
σ_3 (MPa)	0.19	0.76	0.21	0.79
σ_d (MPa)	0.17	0.33	0.21	0.27
σ_d/σ_3 (—)	0.12	0.00	0.18	0.00
θ (MPa)	0.21	0.61	0.24	1.00
τ (MPa)	0.17	0.33	0.21	0.62
ψ_{m-GF} (kPa)	0.77	0.61	0.86	0.27
ψ_{m-FX} (kPa)	0.89	0.61	0.86	0.39
e (—)	0.56	−0.02	0.54	0.37
S (%)	−0.87	−0.69	−0.86	0.35
$w-w_{opt}$ (%)	−0.88	−0.70	−0.86	0.37



Freitas, Ribeiro, Gitirana Jr. (2020)

Módulo de Resiliência: efeito das condições não saturadas



Properties	Lateritic soil (SUB1)			Non-lateritic soil (SUB2)		
	Target	Mean	CV (%)	Target	Mean	CV (%)
w (%)	17.5	16.9	1.10	13.4	12.8	1.57
ρ_d (g/cm ³)	1.720	1.700	0.13	1.800	1.770	0.12
e (—)	0.570	0.585	0.35	0.500	0.523	0.35
S (%)	82.9	78.0	1.24	72.1	58.9	1.60



Freitas, Ribeiro, Gitirana Jr. (2020)

Módulo de Resiliência: efeito das condições não saturadas

Properties	Lateritic soil (SUB1)			Non-lateritic soil (SUB2)		
	Target	Mean	CV (%)	Target	Mean	CV (%)
w (%)	17.5	16.9	1.10	13.4	12.8	1.57
ρ_d (g/cm ³)	1.720	1.700	0.13	1.800	1.770	0.12
e (—)	0.570	0.585	0.35	0.500	0.523	0.35
S (%)	82.9	78.0	1.24	72.1	58.9	1.60





Freitas, Ribeiro, Gitirana Jr. (2020)

Módulo de Resiliência: efeito das condições não saturadas



Properties	Lateritic soil (SUB1)			Non-lateritic soil (SUB2)		
	Target	Mean	CV (%)	Target	Mean	CV (%)
w (%)	17.5	16.9	1.10	13.4	12.8	1.57
ρ_d (g/cm ³)	1.720	1.700	0.13	1.800	1.770	0.12
e (—)	0.570	0.585	0.35	0.500	0.523	0.35
S (%)	82.9	78.0	1.24	72.1	58.9	1.60




Freitas, Ribeiro, Gitirana Jr. (2020)

Aplicação de tecnologias de solos não saturados à engenharia de pavimentos: modelagem


Análise solo-atmosfera

Décadas de 1960 a 1990



Cedergren (1980)

Simulações atuais



Gitirana Jr. & Fredlund (2020)

Análise solo-atmosfera

Laws of conservation

$$\frac{\partial \sigma_{kl}}{\partial x_l} + F_k = \rho \frac{Du_k}{Dt}$$

$$\frac{\partial(\rho_w v_l^w)}{\partial x_l} + \frac{\partial(\rho_w \theta_w)}{\partial t} = 0$$

$$\frac{\partial(\rho_a v_l^a)}{\partial x_l} + \frac{\partial(\rho_a \theta_a)}{\partial t} = 0$$

$$\frac{\partial q_l^h}{\partial x_l} + \frac{\partial \theta_q}{\partial t} = 0$$

State variables

$$(\sigma_{ij} - \delta_{ij} u_a) \quad (u_a - u_w) \quad (u_a)$$

$$\varepsilon_{kl} = \frac{1}{2} \left(\frac{\partial u_k}{\partial x_l} + \frac{\partial u_l}{\partial x_k} \right)$$

Constitutive models

$$\sigma_{ij} = C_{ijkl} \varepsilon_{kl}$$

$$\rho_{a,v} = \frac{W_a}{RT} \bar{u}_{a,v}$$

$$v_l^w = -k_l^w \frac{\partial h^w}{\partial x_l} - k_l^{vd} \frac{\partial h^v}{\partial x_l} - k_l^{va} \frac{\partial h^a}{\partial x_l} \dots$$


Análise solo-atmosfera

Ciclo hidrológico

Modificado de
Eagleson (1970)




Condições
de fronteira

Fluxos
internos



Análise solo-atmosfera


Interação solo-atmosfera durante o empilhamento de rejeitos filtrados de minério de ferro: dados de entrada




Marinho, Gitirana Jr., Amaral, Dias, Silva (2026)
Submetido, aguardando decisão editorial

Análise solo-atmosfera

Oscilação do perfil de grau de saturação




Análise paramétrica



Marinho, Gitirana Jr., Amaral, Dias, Silva (2026)

Análise solo-atmosfera

Resistência de ponta (CPT) corrigida em função da sazonalidade



Marinho, Gitirana Jr., Amaral, Dias, Silva (2026)

Funções de pedo-transferência

PRO-MeDiNa: resumo dos ensaios, normas e quantidade de coleta de materiais


Material	Ensaio	Norma	Quantidade de coleta (por camada)
Misturas asfálticas - Desejáveis	Stress		300 kg na proporção do projeto de dosagem + 60 kg material de enchimento.
	Módulo		
	Fadiga		
Ligantes asfálticos - Obrigatórios	Ponto de Viscosidade		36 litros
	Recuperação		
	Estabilidade (apenas)		
	Determinação de Performance		
	Rolling Thin		
Ligantes asfálticos - Desejáveis	Pressurized		36 litros
	Dinamic		
	Multiple Recovery (MSCR)		
	Linear Amplitude Sweep (LAS)		
		DNIT 423/2020 - ME	
		DNIT 439/2022 - ME	

Material	Ensaio	Norma	Quantidade de coleta (por camada)
Solos e Materiais Granulares		DNIT 23/2018 - ME	350 kg se totalmente passante na peneira de 25 mm. 600 kg se for apenas parcialmente passante na peneira de 25 mm.
Materiais Estabilizados Quimicamente		DNIT 135/2018 - ME	350 kg se totalmente passante na peneira de 25 mm + 100 kg de material estabilizante. 600 kg se for apenas parcialmente passante na peneira de 25 mm + 100 kg de material estabilizante.
Misturas asfálticas - Obrigatórios		DNIT 183/2018 - ME	100 kg de mistura usinada (pronta) + 300 kg na proporção do projeto de dosagem + 60 kg material de enchimento.
	Módulo de Resiliência	DNIT 135/2018 - ME	
	Fadiga	DNIT 183/2018 - ME	
	Flow Number	DNIT 184/2018 - ME	



Comportamento não saturado

- ▶ MR e DP vs. variação de sucção
- ▶ Curva característica
- ▶ Permeabilidade não saturada



Funções de pedo-transferência

► Modelagem teórica

- Busca da relação entre propriedade físicas do solo e suas características de retenção
- Papel da granulometria
- Desafio: estrutura agregada/cimentada.



Alves, Gitirana Jr.,
Vanapalli (2025, 2026)



Modeling the bimodal SWCC of highly weathered tropical soils using grain-size information

Roberto D. Alves^{a,b}, Gilson de F.N. Gitirana Jr.^{a,*}, Sai K. Vanapalli^b

^a Universidade Federal de Goiás, School of Civil and Environmental Engineering, 74605-220 Goiânia, Brazil

^b University of Ottawa, Department of Civil Engineering, K1N 6N5 Ottawa, Canada

ARTICLE INFO

Keywords:
Pore-size distribution
Particle-size distribution
Pedotransfer function
Water retention curve
Lateritic soils

ABSTRACT

The soil-water characteristic curve (SWCC) of highly weathered tropical soils is often bimodal, presenting two main slopes that are strongly related to the macro and micropores. The bimodal SWCC behavior is commonly attributed to fine particle aggregations that affect soil fabric and its pore-size distribution. In this paper, the relationship between basic soil properties (e.g., the Atterberg limits and the grain-size distribution) and the bimodal SWCCs are investigated using a database comprised of 40 different remolded and undisturbed soils. The proposed modeling framework is based on the relationship between the pore-size and the grain-size distributions, using a newly proposed soil property called the β -function. The findings suggest that microporosity has a strong relationship with the liquid limit whereas the total porosity varies mainly as a function of the macrostructure. The grain-size distribution curves under aggregated and disaggregated conditions offer key information on the degree of aggregation and, consequently, on the retention properties of macro and micropores. Several basic soil properties are found to be related to the desaturation zones of the micro and macropores, including the coefficient of uniformity of the fine particle range and the degree of particle aggregation. The developed model offers reasonable estimations for suctions up to approximately 20,000 kPa, with performance exceeding R^2 values of 0.80.

1. Introduction

The soil-water characteristic curve (SWCC) is typically defined as the relationship between the water content and soil suction. The SWCC is considered a key property for understanding and modeling unsaturated soil behavior (Fredlund and Xing, 1994). The SWCC allows the determination of other hydromechanical properties, such as the hydraulic conductivity and shear strength functions, and some volume change parameters. Consequently, the SWCC is useful in the design of geotechnical structures, including foundations, retaining walls, slopes, cover systems, and pavements that involve unsaturated soils.

Multiple physicochemical aspects may influence the main soil-water storage mechanisms, which are mostly related to adsorption and capillarity phenomena (Liu et al., 2024b). The adsorption is closely related to the mineralogy and chemical factors, such as the cation exchange capacity and the specific surface area (Tulier and Or, 2005; Likos and Janfar, 2013; Revil and Lu, 2013; Kyokawa, 2021). The capillarity is mainly related to the pore-size distribution (PSD), which depends on physical attributes of the soil fabric, such as the size, shape, and

arrangement of the particles (Arya and Paris, 1981; Aubertin et al., 2003; Miller et al., 2008).

Some soils present two distinct pore-size families, resulting in a bimodal SWCC. The bimodal nature of SWCCs of some soils can be associated with gap-graded grain-size distributions (GSD) or with specific soil fabric conditions (Delage and Lefebvre, 1984; Romero and Simms, 2008; Satyanaga et al., 2013). Bimodal SWCCs may also be the result of porous particles, as found in diatomaceous earth (Burger and Shackelford, 2001). It is important to note that different factors leading to bimodal SWCCs require different modeling approaches.

Highly weathered tropical soils, also identified as lateritic soils, often exhibit bimodal SWCCs. These soils and their properties are typically associated with pedogenesis conditions marked by abundant annual precipitation combined with high temperature, being predominant in several countries, including Brazil (Huat et al., 2013; Canapum de Carvalho et al., 2023). Lateritic soils are found in regions that have predominantly rainy and dry seasons. During the rainy season, downward flux promotes the removal and transportation (i.e., leaching) of the particles of silica closer to the soil surface. During the dry season, the flow of water is reversed by means of capillary and evaporative action.

* Corresponding author.

E-mail addresses: ralve026@uottawa.ca (R.D. Alves), gilsongitirana@ufg.br (G.F.N. Gitirana), sai.vanapalli@uottawa.ca (S.K. Vanapalli).

<https://doi.org/10.1016/j.enggeo.2025.109031>

Received 29 April 2024; Received in revised form 4 December 2024; Accepted 13 March 2025


Available online 20 March 2025

0013-7952/© 2025 Elsevier B.V. All rights are reserved, including those for text and data mining, AI training, and similar technologies.


Funções de pedo-transferência

► Modelagem teórica

- Interpretação da granulometria nos estados agregado e desagregado



(a)



(b)

Funções de pedo-transferência

► Modelagem teórica

- Relação entre tamanho de partícula e tamanho de poro


$$\beta = \exp \left[\ln \beta_M + \frac{\ln \beta_m - \ln \beta_M}{1 + (\delta_g / \delta_{g0})^{n_c}} \right]$$

$$V_v = \frac{e_m}{\rho_s} \int_{\delta_{g,min}}^{\delta_{g0}} g(\delta_g) d\delta_g + \frac{e_M}{\rho_s} \int_{\delta_{g0}}^{\delta_{g,max}} g(\delta_g) d\delta_g$$

$$\theta_i = \rho_d \int_{\delta_{g,min}}^{\delta_{g,i}} V_{vi}(\delta_g) d\delta_g = \rho_d \sum_{i=1}^i V_{v,i}$$

$$(u_a - u_w) = \frac{4T_s}{\delta_p}$$


$$\beta(\delta_g) = \frac{\delta_g}{\delta_p}$$




Funções de pedo-transferência

► Modelagem teórica

► Base de dados



(a)





(b)

Funções de pedo-transferência

► Modelagem teórica

► Função beta retrocalculada

$$\beta(\delta_g) = \frac{\delta_g}{\delta_p}$$




Funções de pedo-transferência

► Modelagem teórica


► Grau de agregação

$$RA = \frac{\sum_{i=1}^n (P_{A,i} - P_{D,i}) \log(\delta_i / \delta_{i+1})}{\sum_{i=1}^n P_{D,i} \log(\delta_i / \delta_{i+1})}$$



Funções de pedo-transferência


► Modelagem teórica



Funções de pedo-transferência

► Modelagem teórica


Solos compactados



Funções de pedo-transferência

► Modelagem teórica


Solos indeformados



Funções de pedo-transferência

► Modelagem teórica


Solos indeformados




Funções de pedo-transferência

► Modelagem teórica

- Desempenho do modelo de previsão



Resultado para solos remoldados
Desempenho é um pouco inferior para
solos indeformados



Previsão da curva característica

- ▶ Uso de técnicas de aprendizado de máquina
 - ▶ Previsão de umidade correspondente a sucções pré-definidas
 - ▶ Previsão de umidade correspondente a qualquer sucção
 - ▶ Previsão dos parâmetros de um modelo escolhido (e.g., van Genuchten, 1980)
- ▶ Dados de entrada típicos
 - ▶ Peso específico, granulometria, porosidade
 - ▶ M.O., pH, Plasticidade, etc.



Soil & Tillage Research 248 (2025) 106466



Contents lists available at ScienceDirect

Soil & Tillage Research

journal homepage: www.elsevier.com/locate/still



Artificial neural networks for the prediction of the soil-water characteristic curve: An overview

Sávio A. dos Santos Pereira^{a,*}, Gilson de F.N. Gitirana Jr.^{a,2}, Thiago Augusto Mendes^{b,3}, Raphael de Aquino Gomes^{b,4}

^a School of Civil and Environmental Engineering, Universidade Federal de Goiás, Goiânia 74605-220, Brazil
^b Federal Institute of Education, Science and Technology of Goiás, Goiânia 74055-110, Brazil

ARTICLE INFO

Keywords:
Artificial Intelligence
Pedotransfer function
Machine Learning
Soil-water retention

ABSTRACT

Several models have been developed for predicting the soil-water characteristic curve (SWCC). Artificial Neural Networks (ANN), which are machine learning systems based on biological neural networks, are among the techniques used for SWCC prediction. This article presents a literature review of the main SWCC prediction models created using ANNs, including a detailed overview and comparison of the different architectures and their selected hyperparameters. The paper demonstrates the progress made in the field, indicates the next challenges for SWCC prediction using ANNs, and provides a benchmark for the construction of future networks. It is shown that three main approaches have been adopted when modeling SWCC using ANN: predicting the water content corresponding to suction values predefined by the ANN developer or to suction values specified by the user and predicting the coefficients of common fitting equations. Most models used volumetric water content, while some used normalized volumetric water content, and gravimetric water content to quantify water storage. These models usually have a single hidden layer, with the number of neurons per layer varying between 1 and 400. The main input variables are the complete grain-size distribution, soil texture parameters, bulk density, and porosity. The databases used for the development of each model varied in size, comprising between 23 and 3850 SWCCs and between 794 and 13230 water content data points. The developed models have an average R^2 of 0.75 and an RMSE of $0.05 \text{ cm}^3 \text{ cm}^{-3}$. Most models were developed using databases of unimodal materials from temperate regions, with only one model having considered bimodal and tropical soils. Current ANN designs seem compatible with the size of existing databases and input data but will require revisions as more soil information becomes available.

1. Introduction

The soil-water characteristic curve (SWCC) and the hydraulic conductivity function are essential properties in the context of unsaturated soil studies. These parameters can be obtained by direct measurement or using prediction methods based on pedotransfer functions (PTFs) (Bouma, 1989; Bouma and van Lanen, 1987; Wösten et al., 2001). PTFs indirectly relate different soil characteristics and properties (Patil and Singh, 2016). For instance, PTFs for the estimation of the SWCC

generally use readily accessible soil data, such as the grain-size distribution (GSD) and bulk density (Bonala et al., 2012; Kotlar et al., 2020). The importance of the SWCC is increased by the fact that the hydraulic conductivity function is typically estimated using the SWCC (Fredlund et al., 2012).

PTFs can be categorized into two types: mechanistic and empirical models (Patil and Singh, 2016). The mechanistic equations utilize basic soil properties to estimate an equivalent pore-size distribution from which water content can be directly obtained with matric suction being

* Corresponding author.

E-mail addresses: savioaperecido1@gmail.com (S.A. dos Santos Pereira), gilsongitirana@ufg.br (G.F.N. Gitirana), thiago.mendes@ufg.edu.br (T.A. Mendes), raphael.gomes@ufg.edu.br (R.A. Gomes).

¹ ORCID: 0000-0001-6614-0026

² ORCID: 0000-0001-5355-673X

³ ORCID: 0000-0001-6910-5722

⁴ ORCID: 0000-0002-6036-7670

<https://doi.org/10.1016/j.still.2025.106466>

Received 9 November 2023; Received in revised form 16 January 2025; Accepted 10 January 2025


Available online 26 January 2025

0167-1967/© 2025 Elsevier B.V. All rights are reserved, including those for text and data mining, AI training, and similar technologies.

Previsão da curva característica

- ▶ Uso de técnicas de aprendizado de máquina
- ▶ Características dos modelos
 - ▶ Poucas, tipicamente apenas uma camada oculta
 - ▶ Neurônios: 1 a 400
 - ▶ Função de ativação: tanh, linear, sigmoid, ReLu
 - ▶ Épocas: até 50 a 50,000
 - ▶ Fração típica de dados para treinamento: 70 a 80%
 - ▶ Otimização: algoritmo de retropropagação
- ▶ Bases de dados
 - ▶ 23 a 3850 curvas
 - ▶ 794 a 13,230 pontos
 - ▶ Predominância de bases de dados de solos de clima temperado



Objective: Find the weight matrices so that they minimize ξ



**Estrutura típica de um modelo
“multilayer perceptron feed-forward”**

Previsão da curva característica


- ▶ Uso de técnicas de aprendizado de máquina
- ▶ Desempenho dos modelos
 - ▶ Em geral, $RMSE < 0,10 \text{ cm}^3 \text{ cm}^{-3}$
 - ▶ R^2 médio de 0,75
 - ▶ UDS: desempenho ligeiramente superior
 - ▶ DDS: arquiteturas todas muito semelhantes
 - ▶ PCE: desempenho mais variável
 - ▶ Abordagem ideal: não é possível indicar



Desempenho de modelos utilizando RNAs
em função do tipo de abordagem

Previsão da curva característica

- ▶ Uso de técnicas de aprendizado de máquina
- ▶ Desempenho dos modelos
 - ▶ Bases menores produzem modelos melhores (!!!)
 - ▶ Motivo: bases maiores tendem a combinar mais tipos de solos (bases mais heterogêneas)
 - ▶ Solução: as bases maiores, que combinar solos de diferentes regiões, precisariam ser ainda maiores



Desempenho de modelos utilizando RNAs em função do tamanho da base de treinamento

Previsão da curva característica

► RNA para solos lateríticos bimodais

- Solos muito comuns em regiões de clima tropical
- Modelos indisponíveis
- Deve considerar, por exemplo, agregações



Pereira, Silva Jr., Mendes,
Gitirana Jr., Alves (2023)

Geotech Geol Eng
<https://doi.org/10.1007/s10706-023-02716-x>

ORIGINAL PAPER



Prediction of Soil–Water Characteristic Curves in Bimodal Tropical Soils Using Artificial Neural Networks

Sávio Aparecido dos Santos Pereira · Arlam Carneiro Silva Junior ·
Thiago Augusto Mendes · Gilson de Farias Neves Gitirana Junior ·
Roberto Dutra Alves

Received: 20 July 2023 / Accepted: 27 November 2023
© The Author(s), under exclusive licence to Springer Nature Switzerland AG 2023

Abstract Laborious and time-consuming tests are required for the determination of the soil–water characteristic curve (SWCC), often leading to the adoption of estimation methods. To answer the challenge of SWCC prediction, numerous pedotransfer functions (PTF) have been developed. Yet, previous studies have not considered the special behavior of bimodal tropical soils. These materials present dual porosity that is generally attributed to particle aggregation. This paper presents a novel PTF, specifically designed for bimodal tropical soils and based on artificial neural networks (ANNs). The model was trained and tested utilizing a database that was assembled containing soils from tropical regions of Brazil and featuring data for the grain-size distribution

(GSD), consistency limits, and SWCC. Natural and remolded soils were included in the training database, but no distinction between soil conditions was made in the ANN. GSDs in the aggregated and disaggregated states were used to offer information to the ANN regarding the effect of particle aggregation on the water retention. The developed model was able to reproduce the typical SWCC shape of bimodal soils. Predictions for the degree of saturation were moderately correlated with directly measured data, with a coefficient of determination of 0.69. The air-entry value and residual suction of the macropores proved to be the most difficult SWCC attributes to be estimated. The ANN presented superior performance when compared to other PTFs not designed specifically for bimodal tropical soils, such as the Arya-Paris and ROSETTA models. It can be concluded from the obtained results that the developed ANN architecture

Supplementary Information The online version contains supplementary material available at <https://doi.org/10.1007/s10706-023-02716-x>.

S. A. dos Santos Pereira (✉) · A. C. Silva Junior
Federal Institute of Education, Science and Technology
of Goiás, Aparecida de Goiânia 74968-755, Brazil
e-mail: savioaparecido1@gmail.com

A. C. Silva Junior
e-mail: arlam.junior@ifg.edu.br

Present Address:
S. A. dos Santos Pereira · G. d. Gitirana Junior ·
R. D. Alves
School of Civil and Environmental Engineering,
Universidade Federal de Goiás (UFG), Goiânia 74605-220,
Brazil
e-mail: gilsongitirana@ufg.br

R. D. Alves
e-mail: roberto.dutra@hotmail.com

T. A. Mendes
Graduate Program in Technology, Management
and Sustainability (in Portuguese: Programa de
Pós-Graduação em Tecnologia, Gestão e Sustentabilidade,
PPGTGS), Federal Institute of Education, Science
and Technology of Goiás, Goiânia 74055-110, Brazil
e-mail: thiago.mendes@ifg.edu.br



Published online: 27 December 2023

Springer

Previsão da curva característica

► RNA para solos lateríticos bimodais

- Abordagem parametrizada
- Equação bimodal de Gitirana Jr. & Fredlund (2004)
- Base de dados nacionais
- 870 pontos experimentais
- Estrutura da rede determinada empiricamente
- Plataforma TensorFlow, biblioteca Keras
- Parâmetros de entrada: frações de areia, silte e argila, tanto no caso agregado quando desagregado, LL, IP




Ensaios utilizados

Previsão da curva característica

► RNA para solos lateríticos bimodais

► Previsão dos parâmetros




Parâmetros de grau de saturação

Previsão da curva característica

► RNA para solos lateríticos bimodais

► Previsão dos parâmetros





Parâmetros de sucção

Previsão da curva característica

▶ RNA para solos lateríticos bimodais


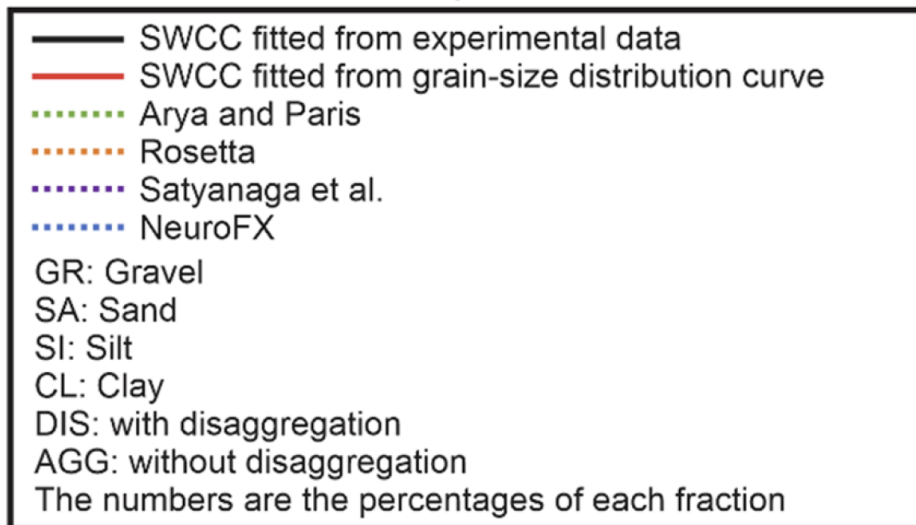
▶ Previsão geral



Previsão da curva característica

► RNA para solos lateríticos bimodais

► Previsão típica





Comparação de modelos

Previsão da curva característica

► RNA para solos lateríticos bimodais

- Importância dos parâmetros de entrada



Barras maiores: parâmetros mais influentes na previsão

Previsão de módulo de resiliência

► Machine Learning





Eq.	Predictors	Multiple R-squared	Adjusted R-squared	F-statistic	p-value
2	σ_3 , σ_1 , w_{opt} , γ_d , $P_{\#200}$, S , SC , C , c'_{MCT} , d'_{MCT} , e'_{MCT}	0.6355	0.6196	39.90	2.20 E-16
3	σ_3 , σ_1 , w_{opt} , γ_d , $P_{\#200}$, S , SC , c'_{MCT} , d'_{MCT} , e'_{MCT}	0.6355	0.6177	35.74	2.20 E-16
4	σ_3 , σ_1 , w_{opt} , γ_d , $P_{\#200}$, SC , c'_{MCT} , d'_{MCT} , e'_{MCT}	0.6277	0.6155	38.60	2.20 E-16
5	σ_3 , σ_1 , w_{opt} , $P_{\#200}$, SC , c'_{MCT} , d'_{MCT} , e'_{MCT}	0.6274	0.6130	43.56	2.20 E-16
6	σ_3 , σ_1 , w_{opt} , $P_{\#200}$, SC , c'_{MCT} , e'_{MCT}	0.5843	0.5703	41.77	2.20 E-16
7	σ_3 , σ_1 , w_{opt} , $P_{\#200}$, SC , e'_{MCT}	0.5579	0.5452	43.96	2.20 E-16
8	σ_3 , σ_1 , w_{opt} , $P_{\#200}$, SC	0.5547	0.5441	53.32	2.20 E-16
9	σ_3 , σ_1 , $P_{\#200}$, SC	0.4629	0.4527	45.47	2.20 E-16
10	σ_3 , σ_1 , SC	0.3285	0.3190	34.57	2.20 E-16



Pascoal, Falcão, Gomes, Souza, Santos, Baroni, Specht (2026)

Previsão de módulo de resiliência

► Machine Learning



Pascoal, Falcão, Gomes, Souza, Santos,
Baroni, Specht (2026)

Comentários finais

- ▶ Não saturados: tecnologias consolidadas
 - ▶ Laboratório
 - ▶ Campo
 - ▶ Modelagem
- ▶ Importância do casamento entre hidrologia e geotecnia
- ▶ Tecnologias aplicáveis em múltiplas escalas
- ▶ Pragmatismo: diferentes níveis de estudos, para diferentes objetivos e momentos de aplicação

Agradecimentos


Grupo de pesquisa da UFG

DNIT/IPR

CNPq

CAPES

FAPEG



Links e contato

- ▶ Para oportunidades de vagas de mestrado, doutorado, pós-doutorado, visite o site do nosso curso de pós-graduação.
- ▶ <https://gecon.eeca.ufg.br/>



- ▶ gilsongitirana@ufg.br